

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Využití adaptivního neuro-fuzzy inferenčního systému ve zpracování plodového EKG

Using Adaptive Neuro-fuzzy Inference System in Processing of Fetal ECG

Zadání diplomové práce

Student:

Bc. Lucie Šajnová

Studijní program:

N2649 Elektrotechnika

Studijní obor:

3901T009 Biomedicínské inženýrství

Téma:

Využití adaptivního neuro-fuzzy inferenčního systému ve zpracování
plodového EKG
Using Adaptive Neuro-fuzzy Inference System in Processing
of Fetal ECG

Jazyk vypracování:

čeština

Zásady pro vypracování:

Cílem diplomové práce je využití neuro-fuzzy inferenčního systému ve zpracování signálu plodového EKG a implementace řešení do programovacího jazyka C#.

Body zadání:

1. Rozbor funkce neuro-fuzzy inferenčního systému a pochopení jeho funkce.
2. Rozbor problematiky zpracování signálu plodového EKG.
3. Implementace neuro-fuzzy inferenčního systému s využitím stávajících implementací v jazyce C#.
4. Provedení experimentálních testů v oblasti potlačení EKG matky za účelem získání EKG plodu.
5. Statistické zhodnocení provedených testů.
6. Závěrečné zhodnocení.

Seznam doporučené odborné literatury:

- [1] NAGEL, Christian, Jay GLYNN a Morgan SKINNER. *Professional C# 5.0 and .NET 4.5.1*. Indianapolis, IN: John Wiley and Sons, 2014. ISBN 978-1-118-83294-3.
- [2] JANG, J. S. R. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*. May/Jun 1993. vol. 23, no. 3, pp. 665-685. ISSN 0018-9472. doi: 10.1109/21.256541.
- [3] MARTINEK, Radek, Radana KAHANKOVA, Homer NAZERAN, et al. Non-Invasive Fetal Monitoring: A Maternal Surface ECG Electrode Placement-Based Novel Approach for Optimization of Adaptive Filter Control Parameters Using the LMS and RLS Algorithms. *Sensors*. 2017. Vol.17, no.5. ISSN 1424-8220. DOI: 10.3390/s17051154. Dostupné také z: <http://www.mdpi.com/1424-8220/17/5/1154>.
- [4] ASSALEH, Khaled. Extraction of Fetal Electrocardiogram Using Adaptive Neuro-Fuzzy Inference Systems. *IEEE Transactions on Biomedical Engineering*. 2007. Vol.54, no.1, 59-68. ISSN 0018-9294. DOI: 10.1109/TBME.2006.883728.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Jaromír Konečný, Ph.D.**

Konzultant diplomové práce: doc. Ing. Radek Martinek, Ph.D.

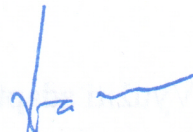
doc. Ing. Martin Černý, Ph.D.

Datum zadání: 01.09.2017

Datum odevzdání: 30.04.2018



doc. Ing. Jiří Koziolek, Ph.D.
vedoucí katedry



prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně. Uvedla jsem všechny literární
prameny a publikace, ze kterých jsem čerpala.

V Ostravě 25. dubna 2018

.....


Ráda bych poděkovala svému vedoucímu diplomové práce Ing. Jaromírovi Konečnému, Ph.D. za věcné připomínky, podporu a vstřícnost při psaní této práce. Dále bych ráda poděkovala doc. Ing. Radkovi Martinkovi, Ph.D. za poskytnutí konzultací týkajících se problematiky plodového EKG a systému ANFIS.

Abstrakt

Tato práce je zaměřena na využití adaptivního neuro-fuzzy inferenčního systému (ANFIS) ve zpracování plodového EKG. v první části je nastíněna problematika plodového EKG. Dále jsou popsány soft-computingové metody jako je fuzzy logika, fuzzy inferenční systém a umělé neuronové sítě. V další části jsou uvedeny adaptivní metody zpracování signálu a samotná implementace softwarového rozhraní využívající adaptivní neuro-fuzzy inferenční systém. V poslední části se přistupuje k testování tohoto systému na různých vstupních signálech a k závěrečnému zhodnocení prováděných experimentů.

Klíčová slova: ANFIS, plodové EKG, neuronové sítě, fuzzy systémy, C#, SNR, PRD, RMSE, adaptivní systém

Abstract

This thesis is focused on the use of the adaptive neuro-fuzzy inference system (ANFIS) in processing of the fetal ECG. In the first part problem of fetal ECG is outlined. There are also described soft-computing methods such as fuzzy logic, fuzzy inference system and artificial neural networks. In the next part are presented the adaptive signal processing methods and the implementation of the software interface using the adaptive neuro-fuzzy inference system. In the last part, the system is tested on different input signals and the final evaluation of experiments.

Key Words: ANFIS, fetal ECG, neural networks, fuzzy systems, C#, SNR, PRD, RMSE, adaptive system

Obsah

Seznam použitých zkratek a symbolů	9
Seznam obrázků	11
Seznam tabulek	13
1 Úvod	14
2 Elektrokardiografie a plodové EKG	15
2.1 EKG křivka	15
2.2 Spektrální vlastnosti EKG	16
2.3 Fetální EKG	17
2.4 Monitorování srdeční aktivity plodu	17
2.5 Extrakce plodového EKG	18
2.6 Předzpracování signálu	18
3 Vybrané soft-computingové metody	19
3.1 Fuzzy logika	19
3.2 Fuzzy inferenční systém	20
3.3 Umělé neuronové sítě	22
4 Adaptivní metody zpracování signálu	25
4.1 LMS	25
4.2 RLS	26
4.3 ADALINE	28
4.4 ANFIS	29
5 Návrh a implementace softwarového rozhraní	37
5.1 GUI	37
5.2 Popis jednotlivých funkcí softwaru	38
5.3 Metody hodnocení kvality filtrace	42
6 Testování adaptivního filtru pro extrakci plodového EKG	44
6.1 Jednoduchá syntetická data	44
6.2 Složitější syntetická data	50
6.3 Reálná data	56
7 Zhodnocení výsledků	62
8 Závěr	64

Literatura	65
Přílohy	68
A Přílohy na CD/DVD	69

Seznam použitých zkratek a symbolů

ANFIS	– Adaptivní Neuro-Fuzzy Inferenční Systém
ANN	– Umělé neuronové sítě (Artificial Neural Networks)
BSS	– Separace zdrojů naslepo (Blind-Source Separation)
CHD	– Vrozené srdeční vady (Congenital Heart Disease)
EKG	– Elektrokardiogram
EMG	– Elektromyogram
FIS	– Fuzzy Inferenční Systém
GUI	– Grafické uživatelské rozhraní (Graphical User Interface)
MSE	– Střední kvadratická chyba (Mean Square Error)[-]
PRD	– Procentuální rozdíl střední kvadratické chyby (Percent Root mean square Difference)[%]
RMSE	– Relativní střední kvadratická chyba (Root Mean Square Error) [-]
SNR	– Odstup signálu od šumu (Signal to Noise Ratio) [dB]
SNR_{vst}	– SNR před fitrací
$SNR_{výst}$	– SNR po filtraci
aEKG	– Abdominální elektrokardiogram
fEKG	– Fetální elektrokardiogram
mEKG	– Elektrokardiogram matky
$sig_{užit}$	– Užitečný signál (ideální fEKG)
$sig_{ruš}$	– Rušivý signál (mEKG po průchodu neznámým prostředím)
sig_{predik}	– Predikovaný signál (výstup z adaptivního systému)
sig_{ideal}	– Ideální průběh fEKG
A	– Fuzzy množina
I	– "Adaptace" nebo "faktor zapomínání"
N	– Uzel třetí vrstvy systému ANFIS (normalizační)
$P(n)$	– Inverzní korelační matice
S	– Množina uzlů
Π	– Uzel druhé vrstvy systému ANFIS
$\Lambda(n)$	– Diagonální matice
Σ	– Uzel páté vrstvy systému ANFIS
α	– Parametr adaptivní sítě
$\vec{k}(n)$	– Vektor zesílení
μ	– Velikost kroku
μ_A	– Funkce příslušnosti
$\mu_A(x)$	– Míra příslušnosti
η	– Míra učení

- w_i – Síla pravidla
- x – Univerzum fuzzy množiny

Seznam obrázků

1	EKG křivka s popisem jednotlivých intervalů a úseků (převzato a upraveno z [17])	15
2	Výkonové spektrum EGG signálu (převzato z [3])	16
3	Časová linie prenatálního vývoje (převzato a upraveno z [27])	17
4	Příklad tvarů funkcí příslušnosti (převzato z [3])	20
5	Takagi-Sugenův fuzzy model (převzato z [3])	21
6	Biologický neuron (převzato z [3])	22
7	Ukázka třívrstvé neuronové sítě (převzato z [13])	23
8	Příklad tvarů funkcí příslušnosti (převzato z [3])	24
9	Blokové schéma FIR filtru s implementovaným algoritmem LMS (převzato z [14])	26
10	Blokové schéma RLS algoritmu (převzato z [14])	27
11	Blokové schéma ADALINE pro extrakci plodového EKG (převzato a upraveno z [15])	28
12	Architektura ANFIS (převzato a upraveno z [5])	31
13	Zjednodušené principiální schéma systému ANFIS pro extrakci fEKG (převzato z [3])	36
14	Grafické rozhraní implementovaného softwaru	37
15	Zobrazení posuvníků v grafu s ukotvenou osou y	38
16	Rozhraní pro spuštění adaptivního systému	39
17	Rozhraní pro spuštění optimalizace	40
18	Vývojový diagram	41
19	Jednoduché syntetické signály	44
20	Výstup adaptivního systému při použití jednoduchých syntetických dat	45
21	3D graf závislosti SNR na počtu epoch a počtu fuzzy pravidel při použití zvonové funkce	47
22	3D graf závislosti SNR na počtu epoch a počtu fuzzy pravidel při použití Gaussovy funkce	47
23	Grafy závislosti daných kritérií na počtu trénovacích vzorků při použití zvonové funkce	48
24	Grafy závislosti daných kritérií na počtu trénovacích vzorků při použití Gaussovy funkce	49
25	Syntetické signály z generátoru	50
26	Výstup adaptivního systému při použití jednoduchých syntetických dat	51
27	3D graf závislosti SNR na počtu epoch a počtu fuzzy pravidel při použití Gaussovy funkce	53
28	3D graf závislosti SNR na počtu epoch a počtu fuzzy pravidel při použití zvonové funkce	53

29	Grafy závislosti daných kritérií na počtu trénovacích vzorků při použití Gaussovy funkce	54
30	Grafy závislosti daných kritérií na počtu trénovacích vzorků při použití zvonové funkce	55
31	Vstupní reálná data	57
32	Výstup adaptivního systému při použití 20 epoch a 20 fuzzy pravidel	58
33	Výstup adaptivního systému při použití 30 epoch a 30 fuzzy pravidel	59
34	Výstup adaptivního systému při použití 40 epoch a 40 fuzzy pravidel	60
35	Výstup adaptivního systému při použití 50 epoch a 50 fuzzy pravidel	61

Seznam tabulek

1	Popis jednotlivých elementů EKG (převzato z [17])	16
2	Tabulka hodnot pro jednoduchá syntetická data	46
3	Tabulka hodnot pro jednoduchá syntetická data	52

1 Úvod

Elektrokardiografie (EKG) je základní vyšetřovací metoda v kardiologii, která se využívá pro snímání a záznam elektrické aktivity srdce. S její pomocí lze například detekovat poruchy srdečního rytmu. Záznam se provádí pomocí elektrokardiografu, kdy samotné snímání napětí z těla vyšetřovaného je realizováno umístěním elektrod na hrudník a končetiny. Výsledný záznam nazýváme elektrokardiogramem.

Fetální elektrokardiogram (fEKG) je nositelem důležitých informací o stavu plodu během těhotenství. Získáme jej měřením elektrických signálů generovaných srdcem plodu, které jsou snímány na těle matky. Extrakce fEKG je velmi důležitá z klinického hlediska pro monitorování a diagnostiku plodů během těhotenství a během porodu. Většina metod pro získání fEKG jsou invazivní, neboli transvaginální, a provádí se umístěním elektrod na hlavu plodu. Tyto metody jsou přesné, ale je možné je použít pouze při porodu. Neinvazivní metody, jinak řečeno transabdominální, se využívají, pokud je třeba získat předporodní fEKG. Tento způsob snímání je preferovanější, neboť je příjemnější pro matku i plod a zároveň jsou minimální rizika oproti invazivnímu fEKG, kde může dojít k zanesení infekce. Touto metodou je však signál degradován množstvím nežádoucích složek, jako je mnohem silnější elektrokardiogram matky (mEKG), síťové rušení či biologické artefakty (např. EMG, děložní kontrakce a jiné) [1], [3] a [5].


Předkládaná práce se zabývá extrakcí plodového EKG pomocí adaptivního neuro-fuzzy inferenčního systému. V první části je nastíněna problematika snímání plodového EKG. V této práci se k extrakci přistupuje pomocí neinvazivních metod. Dále jsou vysvětleny pojmy, jako je fuzzy logika, fuzzy inferenční systém a umělé neuronové sítě. Poté jsou představeny adaptivní metody zpracování signálu. V praktické části je popsána implementace výše zmíněného systému v programovacím jazyku C#. Ověření funkčnosti daného systému je testováno jak na syntetických, tak na reálných datech. V poslední části je zhodnocení daných výstupů po průchodu adaptivním systémem.

2 Elektrokardiografie a plodové EKG

Elektrokardiografie je diagnostická metoda, která umožňuje snímání a záznam elektrické aktivity srdce. Díky této metodě je možné detekovat poruchy srdečního rytmu (tzv. arytmie), ischemické změny v myokardu apod. Záznam elektrické aktivity srdce se provádí pomocí elektrokardiografu, jehož výsledný záznam se nazývá elektrokardiogram [16].

2.1 EKG křivka

Na elektrokardiogramu je vyjádřena rovnou čarou izoelektrická linie. Jakákoliv oblá výchylka nad ní nebo pod ní se nazývá pozitivní nebo negativní vlna. Základní rozlišované vlny na elektrokardiogramu se označují P, T a U. Strmá výchylka se nazývá kmit. Mezi základní rozlišované kmity patří Q, R a S. Dalším elementem, který na elektrokardiogramu pozorujeme je komplex. Jedná se o soubor po sobě jdoucích kmitů. Jediným komplexem v elektrokardiogramu je tzv. komorový komplex označovaný jako QRS komplex. Interval je časový údaj vyjadřující vzdálenost mezi dvěma elementy. V Tabulce 1 je uvedena délka jednotlivých segmentů. Úsekem nebo segmentem je čas od konce některé výchylky do začátku následující. Rozlišujeme PQ a ST úseky. Na Obrázku 1 je zobrazena EKG křivka s vyznačenými elementy.




Obrázek 1: EKG křivka s popisem jednotlivých intervalů a úseků (převzato a upraveno z [17])

Tabulka 1: Popis jednotlivých elementů EKG (převzato z [17])

Elementy	Popis	Délka [ms]
RR interval	interval mezi R kmitem a následujícím R kmitem	600-1200
P vlna	první krátká vlna EKG křivky, odpovídá depolarizaci síní	80
PQ interval	interval od začátku vlny P do začátku QRS komplexu	120-200
QRS komplex	depolarizace komor	80-120
PQ úsek	úsek mezi koncem P vlny a začátkem QRS komplexu	50-120
ST úsek	úsek mezi koncem QRS komplexu a počátkem vlny T	80-120
T vlna	repolarizace komor	160
ST interval	interval od konce QRS komplexu do konce T vlny	320
QT interval	interval mezi začátkem QRS komplexu do konce T vlny	420
U vlna	repolarizace některých částí převodního systému, má nízkou amplitudu a obvykle zcela chybí	-

2.2 Spektrální vlastnosti EKG


Pomocí převodu signálu z časové do frekvenční oblasti se získává frekvenční spektrum, díky němu lze získat přehled o zastoupení jednotlivých složek v útvarech EKG. U dospělého člověka leží využitelná část signálu v kmitočtovém pásmu do 125 Hz, zatímco u dětí a při snímání fEKG až do 150 Hz. Rozložení jednotlivých složek EKG signálu ve frekvenčním pásmu je zobrazeno na Obrázku 2. Pro reprezentaci spektra EKG se využívá především amplitudové spektrum, respektive odhad výkonové spektra.



Obrázek 2: Výkonové spektrum EKG signálu (převzato z [3])

2.3 Fetální EKG

Během těhotenství se stav plodu hodnotí různými technikami. Jednou z těchto metod je ultrazvukové vyšetření. Mezi 18. a 22. týdnem těhotenství se provádí vyšetření na různé fetální anomálie včetně vrozené srdeční vady (CHD - congenital heart disease). Neinvazivní plodový elektrokar-diogram by mohl být cenným nástrojem pro detekci CHD v raném těhotenství. Na Obrázku 3 je časová linie prenatalního vývoje s vyznačenými klíčovými mezníky.



Obrázek 3: Časová linie prenatalního vývoje (převzato a upraveno z [27])

Ve srovnání s jinými technikami monitorování plodu, extrakce plodového EKG zaostává. To je způsobeno několika technickými problémy, které je nutné překonat. Prvním z nich je, že velikost srdce v gestačním věku 20 týdnů má asi 1/10 velikosti dospělého srdce. Vzhledem k nízkému napětí fetálního EKG (asi 1/50 mateřského EKG) je poměr signálu k šumu malý. Kromě toho identifikace fetálních signálů je náročná kvůli maskování mateřským EKG a vysokým hlukům v pozadí, způsobených mateřským elektromyogramem. Plodová voda a mateřská tkáň obklopující plod zvětšují vzdálenost elektrod od fetálního srdce a způsobují nehomogenní tkáňové vedení, které významně zasahuje do kvality požadovaného signálu. Dalším faktorem je rychlost srdeční frekvence plodu, která je dvakrát až třikrát rychlejší než srdeční frekvence dospělého člověka [26].

2.4 Monitorování srdeční aktivity plodu

Samotné měření probíhá tak, že se několik elektrod umístí na břicho matky, nejbližší k srdci plodu, v naději, že alespoň jedna bude mít signál s dost vysokým odstupem signálu od šumu (SNR). Na rozdíl od běžné elektrokardiografie, u monitorování plodového EKG není umístění elektrod nijak standardizováno. Kromě toho se snímá EKG matky umístěním elektrod na hrudník, tzv. mEKG. Časná diagnostika před porodem neinvazivní technikou zvyšuje efektivitu dané léčby. MEKG může mít 5 -1000 krát větší intenzitu než fEKG, proto je vyžadována eliminace mEKG [1].

2.5 Extrakce plodového EKG

Problém extrakce fEKG nelze vyřešit konvenčními filtry. Lineární filtry ve frekvenční doméně nelze použít, neboť rozdíly signálu mezi mEKG, fEKG a hlukem nelze jednoznačně rozeznat. Proto byly zavedeny techniky s různými stupni úspěchu. Tyto techniky zahrnují adaptivní filtry [30], korelační analýzu [33], singulární rozklad [31], vlnkovou transformaci [28], neuronové sítě [29] a separaci zdrojů naslepo (BSS) [32]. U většiny těchto technik probíhá samotné snímání dvojvodičově, tzn., snímá se z hrudníku a břicha matky. Jediná metoda, pro kterou je nutné použít více vodičů je separace zdrojů naslepo, což je její poměrně velká nevýhoda. u ostatních technik je největší úskalí v tom, že se QRS komplex matky překrývá s QRS komplexem plodu, což způsobuje, že v extrahovaném fEKG lze vidět zbytky složek mEKG. Z těchto důvodů se pro extrakci plodového EKG častěji přistupuje k adaptivním metodám, které jsou blíže popsány v kapitole 4 [1], [4].

2.6 Předzpracování signálu

Pro následné zpracování, ukládání a přenos je nutné měřené signály nejdříve zesílit, digitalizovat a filtrovat. Tento blok předzpracování může, ale také nemusí být do systému zařazen, neboť data získané z klinické praxe jsou již většinou předzpracovány.

Po optimálním zesílení měřeného signálu, je nutné jej digitalizovat pomocí analogově digitálního převodníku (A/D převodník). Dalším krokem v předzpracování je samotná filtrace signálu. Běžně se využívají techniky pro filtrování, jako jsou:

- úzkopásmový filtr, neboli Notch filtr na frekvenci 50 Hz k odstranění síťového rušení,
- FIR filtr typu dolní propusti s mezní frekvencí 30 až 35 Hz (u signálu obsahující fEKG se využívá mezní frekvence 40 až 50 Hz) pro odstranění EMG,
- filtr typu horní propusti s mezní frekvencí 0,5 Hz pro kompenzování driftu (kolísání nulové izoliny) [3].

3 Vybrané soft-computingové metody

Tato kapitola je zaměřena na popis vybraných soft-computingových metod, které jsou používány v praxi pro zlepšení kvality diagnostiky abdominálního fEKG, jako jsou:

- fuzzy logika,
- umělé neuronové sítě,
- fuzzy-neuronové sítě.

3.1 Fuzzy logika

Počátek fuzzy logiky a fuzzy množin definoval již v roce 1965 profesor Lofti A. Zadeh, kdy publikoval článek s názvem „Fuzzy sets“, viz [9]. Tato teorie vychází z předpokladu, že velmi často se lze ve světě setkat s objekty, u kterých není přesně definované kritérium příslušnosti. Pro představu máme třídu zvířata, která jasně zahrnuje členy jako je pes, kočka, kůň, a jiné, a zároveň vylučuje objekty, jako jsou kameny, tekutiny, rostliny apod. Objekty jako jsou hvězdice, bakterie atd. mají nejednoznačný stav s ohledem na třídu zvířat [9].

3.1.1 Fuzzy množina

V teorii klasických množin daný prvek do množiny buď patří, nebo patří. Lze tedy hovořit o tzv. plné příslušnosti nebo nepřislušnosti. Ve fuzzy množinové teorii je množina definována jako třída, která přiřazuje prvkům neurčitost pomocí tzv. míry příslušnosti, která může o daném objektu říct, jak hodně patří do dané třídy, např. „strom je málo vysoký“. Z tohoto důvodu bývá fuzzy množina označovaná jako „mlhavá“ či „neurčitá“. Fuzzy množinu je možno definovat jako množinu uspořádaných dvojic:

$$A = (x, \mu_A) \quad (1)$$

kde μ_A je funkce příslušnosti, x je univerzum fuzzy množiny a $\mu_A(x)$ si označíme jako míru příslušnosti.


Pokud:

$\mu_A(x) = 0$ prvek x do množiny A nepatří

$\mu_A(x) = 1$ prvek x do množiny A patří

$\mu_A(x) \in (0, 1)$ nelze s určitostí říct, zda prvek x patří do množiny A , přičemž velikost $\mu_A(x)$ vyjadřuje míru příslušnosti x k A .

Funkce příslušnosti může být definována tabulkou, matematickým výrazem či grafem [3], [10]. Na Obrázku 4 jsou vykresleny některé typy tvarů funkcí příslušnosti.



Obrázek 4: Příklad tvarů funkcí příslušnosti (převzato z [3])

3.2 Fuzzy inferenční systém

Systémové modelování založené na konvenčních matematických nástrojích není vhodné pro špatně definovatelné a nejisté systémy. Avšak fuzzy odvození využívající if-then pravidla může modelovat kvalitativní aspekty lidského poznání a uvažování bez použití kvantitativních analýz. Fuzzy modelování bylo nejprve prozkoumáno systematicky Takagi a Sugenum [7], kteří našli četné praktické aplikace v řízení, predikci a odvození. Nicméně i zde jsou základní aspekty tohoto přístupu, kterým je potřeba lépe porozumět [8].

Konkrétně:

1. Neexistují žádné standartní metody pro transformaci lidských znalostí nebo zkušeností do báze pravidel a databáze fuzzy inferenčního systému.
2. Je potřeba efektivních metod pro ladění funkce příslušnosti, aby se minimalizovala chyba měření na výstupu nebo k maximalizaci indexu výkonu.

Fuzzy if-then pravidla jsou výrazy ve formě IF-THEN, kde A a B jsou fuzzy množiny charakterizované funkcí příslušnosti. Kvůli jejich stručné podobě jsou právě tyto pravidla často využívána k zachycení nepřesných způsobů uvažování, které hrají zásadní roli lidské schopnosti dělat rozhodnutí v prostředí nejistoty a nepřesnosti [8].

$$\text{IF } x \text{ is } a \text{ THEN } y \text{ is } B \quad (2)$$

Příklad:

$$\text{Jestliže (IF) je tlak vysoký, pak (THEN) je objem malý,} \quad (3)$$


kde *tlak* a *objem* jsou jazykové proměnné, *vysoký* a *malý* jsou jazykové hodnoty, které jsou charakterizovány funkcí příslušnosti. Část výrazu vlevo od implikace „THEN“ se nazývá předpokladem, antecedentem či premisou a pravá část je důsledek neboli konsekvent [10].

Další formu fuzzy IF-THEN pravidla navrhl Takagi a Sugeno, která má fuzzy množinu zahrnutou pouze v předpokladu. Ukázka tohoto modelu je na Obrázku 5. Pomocí Takagiho a Sugena můžeme popsat odolnou sílu pohybujícího se tělesa takto:

$$\text{Pokud je rychlost vysoká, pak síla} = k * (\text{velocity})^2, \quad (4)$$

kde *vysoká* je předpoklad charakterizovaný funkcí příslušnosti a konsekvent je popsán obyčejnou rovnicí o vstupní proměnné, tedy rychlosti.

Oba typy IF-THEN pravidla se používají jak v modelování, tak v řízení [7], [8].




Obrázek 5: Takagi-Sugenův fuzzy model (převzato z [3])

3.3 Umělé neuronové sítě

Struktury, které jsou inspirovány svými biologickými vzory, nazýváme umělé neuronové sítě (ANN). Jejich hlavní podstatou je simulace a implementace některých funkcí lidského mozku. Jedná se především o schopnost učení a adaptace. Základním stavebním a funkčním prvkem je neuron, jehož hlavní funkci je možno chápat jako zpracování signálu. Na vstupu jsou z okolních zdrojů přijímány podněty, které jsou systémem vyhodnoceny a na jejich základě vzniká výstup [3], [10].


Schéma biologického neuronu je zobrazeno na Obrázku 6. Základní složky neuronu můžeme popsat jejich biologickými názvy, jako jsou dendrity, soma (tělo), axon a synapse. Dendrity jsou vlasové rozšíření těla, které se chovají jako vstupní kanály. Ty dostávají své vstupy prostřednictvím synapsí jiných neuronů. Soma poté zpracovává tyto příchozí signály a dále je vysílá na jiné neurony přes axon a synapse. Matematickým model neuronu se nazývá perceptron. Neuronové sítě vznikají spojením výstupu jednotlivých neuronů, která se dále spojují s dalšími neurony a vytvářejí neuronovou síť [12].



Obrázek 6: Biologický neuron (převzato z [3])

3.3.1 Struktury neuronových sítí

V časných neuronových sítích se využívaly pouze dvouvrstvé struktury. V druhé generaci neuronových sítí byly vyvinuty nové struktury, které sestávaly ze tří nebo více vrstev. Nejběžněji se však používají 3 vrstvy sítě, které se skládají ze vstupní, skryté a výstupní vrstvy, viz Obrázek 7. Mezi dvěma sousedními vrstvami se nachází tzv. úplné propojení neuronů, to znamená, že každý neuron nižší vrstvy je spojen se všemi neurony vyšší vrstvy [13], [18].



Obrázek 7: Ukázka třívrstvé neuronové sítě (převzato z [13])

Dopředné síť

Tyto sítě vypočítají váhy, které se použijí k určení výstupu z uzlu, který je následně přiváděn do další vrstvy. Způsob jakým je informace zpracována lze popsat v následujících krocích:

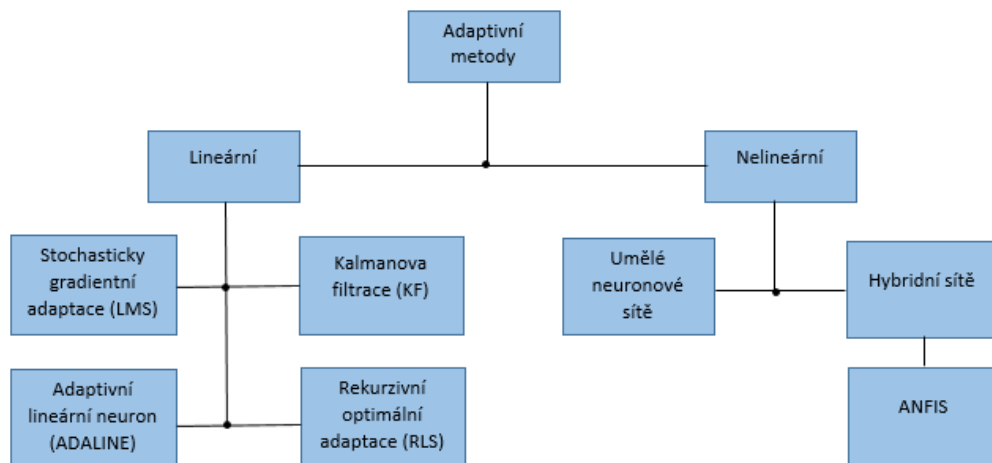
1. Nejdříve jsou neurony excitovány na odpovídající úroveň vstupní vrstvy.
2. Tyto excitace jsou následně pomocí vazeb přivedeny k následující vrstvě a upraveny (zeslabeny nebo zesíleny) pomocí synaptických vah.
3. Každý neuron v této vyšší vrstvě provede sumaci upravených signálů od neuronů nižší vrstvy a je excitován na úroveň danou svou aktivační funkcí.
4. Tento proces dále probíhá přes všechny vnitřní vrstvy až k vrstvě výstupní, kde získáme excitační stavy všech neuronů [18].

Sítě se zpětnou vazbou

Oživení neuronových sítí začalo na počátku 80. let práci Hopfielda [19]. Hopfieldův model byl zcela odlišný od dřívějších přístupů v tom, že neurony nebo uzly měly obousměrné spojení. Namísto přizpůsobení váhy pro vyladění výstupu uzlů, jsou v síti uloženy vzory, které byly později použity pro zpracování neznámých vstupních vektorů [13].

3.3.2 Adaptivní sítě

Adaptivní síť je síťová struktura sestávající z uzlů a směrových vazeb, přes které jsou uzly připojeny. Navíc, část nebo všechny uzly jsou adaptivní, což znamená, že jejich výstupy závisí na parametru (parametrech) vztahujícím se k těmto uzlům a pravidlech učení, jak mají být tyto parametry změněny, aby minimalizovaly chybu měření.



Obrázek 8: Příklad tvarů funkcí příslušnosti (převzato z [3])

4 Adaptivní metody zpracování signálu

Adaptivní metody se využívají k odstranění šumu v pozadí z užitečného signálu. Jedná se o velmi užitečnou techniku, kdy je signál ponořen ve velmi hlučném prostředí. Obvykle šum v pozadí není stabilní a v čase se mění. Odstranění tohoto rušení je tedy nutné pomocí adaptivního procesu, který by měl být schopen pracovat s měnícími se podmínkami a musí být schopen se přizpůsobit měnícímu se prostředí. Podrobné rozdělení adaptivních metod zobrazuje Obrázek 8. Mezi tyto metody patří i adaptivní neuro-fuzzy interferenční systém (ANFIS) jenž je v poslední době často využíván k extrakci fEKG [1].

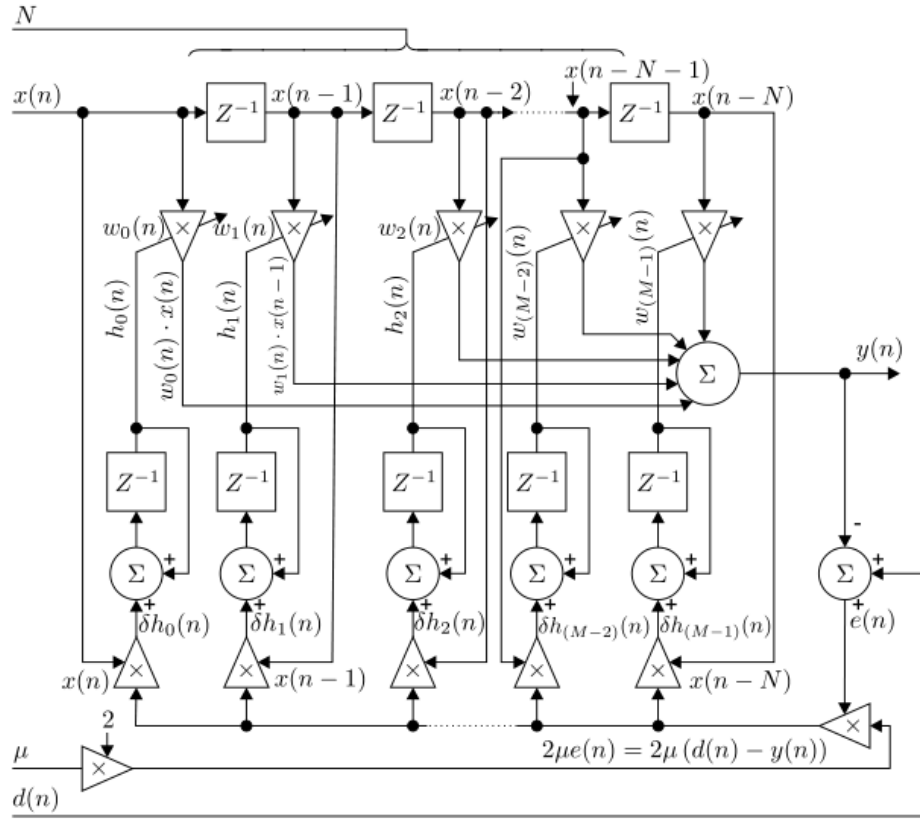
4.1 LMS

Základním představitelem třídy stochastických gradientních adaptivních algoritmů je LMS algoritmus, který využívá teorie Wienerovy filtrace stochastického průměrování a metody nejmenších čtverců.

Iterační výpočet koeficientů lineárního adaptivního algoritmu LMS je dán rovnicí:

$$w(n+1) = w(n) + 2\mu e(n)x(n), \quad (5)$$

kde $x(n)$ je vstupní vektor zpožděných (N) hodnot měřeného signálu. Vektor $w(n)$ představuje impulsní charakteristiku filtru v čase n . Konstanta μ udává velikost kroku a má zásadní vliv na rychlost a stabilitu konvergence adaptivního algoritmu. Dosazení malé kladné konstanty za μ je nezbytné pro správnou činnost tohoto algoritmu. Bude-li zvolená hodnota příliš malá, zvýší se čas k nalezení optimálního řešení adaptivním filtrem. Naopak pokud bude hodnota příliš velká, adaptivní filtr bude nestabilní a výsledný výstup bude vykazovat odchylky [3], [14].



Obrázek 9: Blokové schéma FIR filtru s implementovaným algoritmem LMS (převzato z [14])

4.2 RLS

RLS algoritmus považován za základního představitele třídy rekurzivních optimálních adaptivních algoritmů, který je založen na teorii Kalmanovy filtrace, časovém průměrování a metodě nejmenších čtverců. Implementaci RLS algoritmu lze shrnout následovně:

$$\text{Začátek } \vec{w}(n=0) = \vec{0} \quad (6)$$

$$P(n=0) = \delta^{-1} \cdot I; \delta \in R \quad (7)$$

$$\text{Pro } (n = 1, 2, \dots, N) : \quad (8)$$

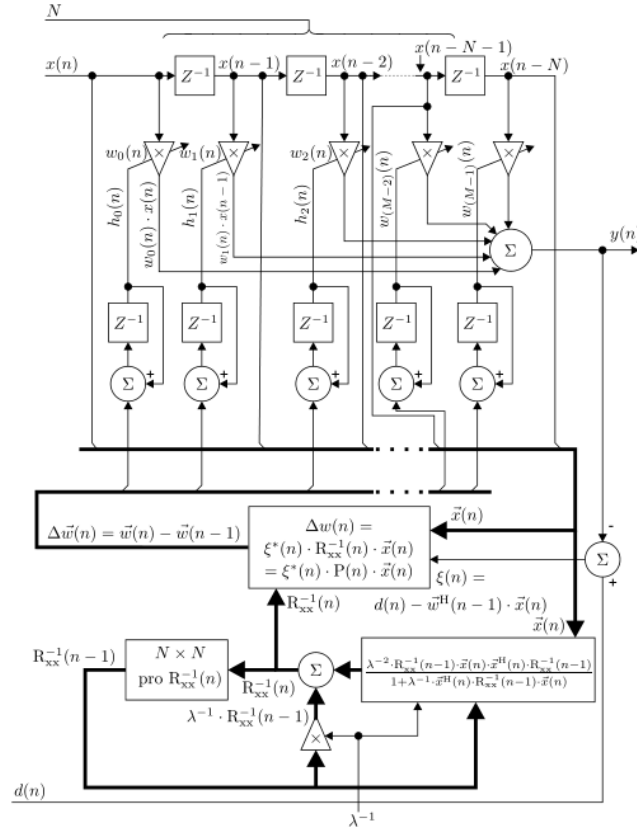
$$\vec{k}(n) = \frac{\lambda^{-1} P(n-1) \cdot \vec{x}(n)}{1 + \lambda^{-1} \cdot \vec{x}^T(n) P(n-1) \cdot \vec{x}(n)} \quad (9)$$

$$\xi(n) = d(n) - \vec{w}^T(n-1) \cdot \vec{x}(n) \quad (10)$$

$$\vec{w}(n) = \vec{w}(n-1) + \xi(n) \cdot \vec{k}(n) \quad (11)$$

$$P(n) = \lambda^{-1} \cdot P(n-1) - \lambda^{-1} \cdot \vec{k}(n) \cdot \vec{x}^T(n) \cdot P(n-1), \quad (12)$$

kde $P(n)$ označuje inverzní korelační matici vstupního signálu, $\vec{k}(n)$ je vektor zesílení a $\Lambda(n)$ je diagonální matice sestávající s váhových faktorů λ^{n-i} . Takzvaná “adaptace” nebo “faktor zapomínání” I je v rozsahu $0 < I < 1$. Tento parametr ovlivňuje proces “zapomenutí”, tj. dává větší váhu nedávným vzorkům odhadů chyb ve srovnání se staršími vzorky. Pokud $\lambda = 1$, pak je odhad bez zapomínutí, tj. je roven běžné metodě nejmenších čtverců. Váha faktoru λ^{n-i} ovlivňuje váhy, kde jsou vstupní hodnoty považovány za nulové pro $i < 1$ a poslední n vzorky jsou nejdůležitější. Pro implementaci je hodnota “faktoru zapomínání” obvykle v rozmezí $0,98 < \lambda < 1$. Malá hodnota λ způsobuje, že filtr kladě větší důraz na nedávné vzorky pozorovaných dat a má tendenci zapomínat na minulost [14].

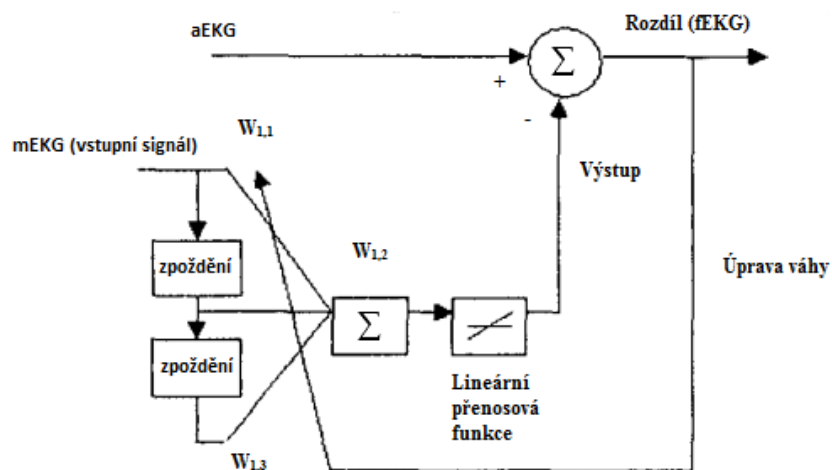


Obrázek 10: Blokové schéma RLS algoritmu (převzato z [14])

4.3 ADALINE

Adaptivní filtr lineární neuronové sítě využívá algoritmu LMS. ADALINE může reagovat na změny ve svém prostředí. Lineární sítě jsou nastaveny v každém časovém okamžiku na základě vstupních a cílových vektorů. Mohou nalézt váhy a podněty, které minimalizují chybu algoritmu LMS pro poslední vstupy a cílové vektory. Adaptivní lineární síť (ADALINE) používá přístup adaptivního filtrování, tedy kombinace ADALINE a zpožďovací linky.

Adaptivní lineární neuronovou síť lze využít pro extrakci fEKG z břišního EKG. Charakteristika, která umožňuje extrakci plodu, je způsobena korelací mezi mateřským EKG signálem s abdominálním EKG signálem. Síť pokládá vstupní signál (mEKG) co nejblíže k cílovému signálu (aEKG), takže chyba mezi mateřským signálem a signálem snímaným na břicho by měl představovat EKG plodu. MEKG je signálem, který by měl být síti předvídan a vstupuje do sítě prostřednictvím zpožděné linky. Blokové schéma pro extrakci plodového EKG pomocí ADALINE je zobrazeno na Obrázku 11.



Obrázek 11: Blokové schéma ADALINE pro extrakci plodového EKG (převzato a upraveno z [15])

Hodnota, která vstupuje do sítě je aktuální hodnotou. Dva výstupy ze zpožďovacích linek jsou předchozími hodnotami aktuální hodnoty EKG. Tři hodnoty jsou násobeny hodnotou tří váh. Vzhledem k tomu, že cílem je abdominální EKG, tak síť změní váhu v každém časovém okamžiku, aby se minimalizovala chyba. Pokud je chyba rovna nule, pak je výstup přesně shodný s cílovým EKG.

4.4 ANFIS

ANFIS je hybridní adaptivní síť založená na fuzzy interferenčním systému typu Takagi-Sugeno (FIS), který je implementován společně s umělými neuronovými sítěmi. Využívá algoritmus neuro-adaptivního učení k určení vztahu mezi vstupní a výstupní datovou sadou. Tento učební algoritmus může být hybridní nebo zpětného šíření. Vyznačuje se vysokou schopností shromažďovat neuronovou síť i fuzzy systémy při učení nelinearity. FIS zahrnuje lidské znalosti systému, na rozdíl od ANN, které jsou schopné optimalizovat parametry ANFIS a zajišťovat proces učení. Trénink neuronové sítě je proces určení hodnot parametrů pro trénování dat. Pro správnou funkci systému je třeba zachovat několik základních rysů:

- pouze jeden výstup systému ANFIS,
- fuzzy inferenční systém musí být nultého nebo prvního řádu,
- počet pravidel odpovídá počtu funkcí příslušnosti,
- výstup funkce příslušnosti je konstantní nebo lineární [5], [11].

4.4.1 Architektura ANFIS

Původní Jangova architektura ANFIS [8] sestává z pěti dopředných propojených vrstev (viz Obrázek 12), které jsou popsány níže. Každý uzel vykonává určitou funkci na příchozích signálech a také nastavuje parametry týkající se daného uzlu. Vzorce funkcí uzlu se mohou vzájemně lišit a volba jednotlivé funkce uzlu závisí na celkové funkci vstup-výstup. K odrážení různých adaptivních schopností se využívají kruhové a čtvercové uzly. Čtvercový uzel (adaptivní uzel) má své parametry, zatímco kruhový uzel (pevný uzel) nemá žádné. Soubor parametrů adaptivní sítě je spojení množin parametrů každého adaptivního uzlu. Aby bylo dosaženo požadovaného mapování vstupů a výstupu, jsou tyto parametry aktualizovány podle údajů o tréninku a postupu učení založeného na gradientu.

Předpokládejme, že daná adaptivní síť má L vrstev a $ktá$ vrstva má počet k uzlů. Můžeme označit uzel v $itě$ pozici $kté$ vrstvy jako (k, i) a funkci uzlu jako O_i^k . Vzhledem k tomu, že výstup uzlu závisí na jeho předchozích signálech a nastavených parametrech, získáme:

$$O_i^k = O_i^k(O_1^{k-1}, \dots, O_{(k-1)}^{k-1}, a, b, c, \dots), \quad (13)$$

kde a, b, c , atd. jsou parametry vztahující se k tomu uzlu. Za předpokladu, že daná množina tréninkových dat obsahuje P záznamy, je možné definovat chybu (nebo energetickou funkci) pro

p tý ($1 \leq p \leq P$) zápis údajů o tréninku jako součet čtvercových chyb:

$$E_p = \sum_{m=1}^{(L)} (T_{m,p} - O_{m,p}^L)^2, \quad (14)$$

kde T_m je m tá komponenta p tého cílového vektoru a $O_{m,p}^L$ je m tá komponenta aktuálního výstupního vektoru vytvořená prezentací p tého vstupního vektoru. Proto je celková chyba měření:

$$E = \sum_{p=1}^P E_p. \quad (15)$$

Aby bylo možné vytvořit proces učení, který implementuje gradientní klesání v E přes prostor parametrů, je nutné nejdříve vypočítat chybovou rychlost $\partial E_p / \partial O$ pro p tá tréninková data a pro každý výstupní uzel O . Míra chyby pro výstupní uzel v (L, i) lze snadno vypočítat z:

$$\frac{\partial E_p}{\partial O_{i,p}^L} = -2(T_{i,p} - O_{i,p}^L). \quad (16)$$

Pro vnitřní uzel v (k, i) lze míru chyby odvodit z pravidla řetězce:

$$\frac{\partial E_p}{\partial O_{i,p}^k} = \sum_{m=1}^{(k+1)} \frac{\partial E_p}{\partial O_{m,p}^{k+1}} \cdot \frac{\partial O_{m,p}^{k+1}}{\partial O_{i,p}^k}, \quad (17)$$

kde $1 \leq k \leq L - 1$. To znamená, že chybová hodnota vnitřního uzlu může být vyjádřena jako lineární kombinace míry chyb uzlů v další vrstvě. Proto pro všechny $1 \leq k \leq L$ a $1 \leq i \leq (k)$, je možné nalézt $\partial E_p / \partial O_{i,p}^k$.

Jestliže α je parametr dané adaptivní sítě, pak:

$$\frac{\partial E_p}{\partial \alpha} = \sum_{O^* \in S} \frac{\partial E_p}{\partial O^*} \cdot \frac{\partial O^*}{\partial \alpha}, \quad (18)$$

kde S je množina uzlů, jejichž výstupy závisí na α . Potom odvození celkového chybového měření E vzhledem k α je:

$$\frac{\partial E}{\partial \alpha} = \sum_{p=1}^P \frac{\partial E_p}{\partial \alpha}. \quad (19)$$

Podle toho je aktualizací vzorec pro obecný parametr α

$$\Delta \alpha = -\eta \frac{\partial E}{\partial \alpha}, \quad (20)$$

ve kterém je η míra učení, kterou lze dále vyjádřit jako

$$\eta = \frac{k}{\sqrt{\sum_{\alpha} (\frac{\partial E}{\partial \alpha})^2}}, \quad (21)$$

kde k je velikost kroku, délka každého gradientového přechodu v parametrickém prosotru. Obvykle je možné změnit hodnotu k pro změnu rychlosti konvergence. Ve skutečnosti existují dvě učební paradigma pro adaptivní sítě. Pro dávkové učení (offline učení) je aktualizací vzorec pro parametr α založen na (19) a aktivace aktualizace probíhá teprve po předložení celé sady tréninkových dat, tedy teprve po každé epoše.

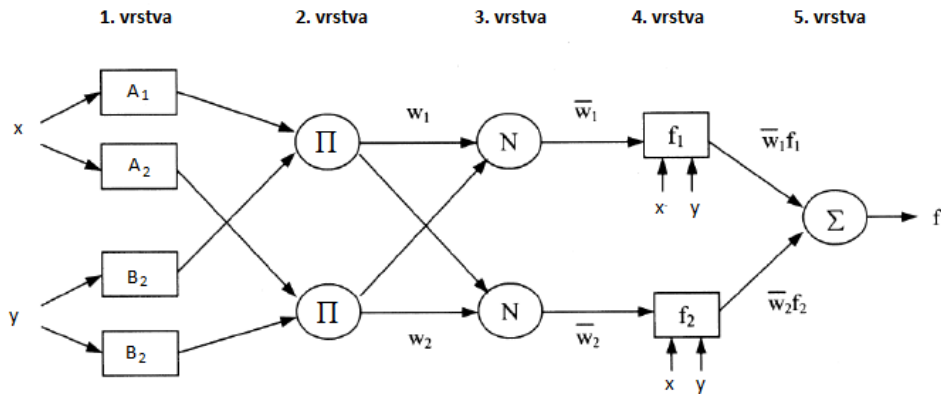
Naproti tomu, pokud je třeba parametry aktualizovat bezprostředně poté, co byl představen každý pár vstupů a výstupů, pak je vzorec pro aktualizaci založen na (18) a je označován jako vzorkové učení (online učení).

Pravidlový model typu Sugeno je tvořen dvěma pravidly if-then v tomto tvaru:

$$\text{IF } (x \text{ is } A_1) \text{ and } (y \text{ is } B_1) \text{ THEN } (f = p_1x + q_1y + r_1), \quad (22)$$

$$\text{IF } (x \text{ is } A_2) \text{ and } (y \text{ is } B_2) \text{ THEN } (f = p_2x + q_2y + r_2), \quad (23)$$

kde x a y jsou počáteční vstupy, A_i a B_i jsou nelineární fuzzy množiny nazývané také jako předpoklad, f_i je výstup systému a p_i , q_i a r_i jsou konstrukční lineární parametry, které jsou určeny během procesu trénování [5], [11].



Obrázek 12: Architektura ANFIS (převzato a upraveno z [5])

1. Vrstva

První vrstva architektury je adaptivní. Používá se pro fuzzifikaci vstupních proměnných. Každý uzel představuje vstupní hodnotu jazykové proměnné. Každý uzel i v této vrstvě je čtvercový s funkcí uzlu:

$$O_i^1 = \mu_{Ai}(x); i = 1, 2, \quad (24)$$

$$O_i^1 = \mu_{Bi-2}(y); i = 3, 4, \quad (25)$$

kde x a y jsou vstupy uzlu i , A a B jsou jazykové štítky a $\mu_{Ai}(x)$, respektive $\mu_{Bi-2}(y)$ mohou přijmout jakoukoliv funkci příslušnosti. Nejčastěji se však využívá Gaussova nebo zvonová funkce.

2. Vrstva

Každý uzel v této vrstvě je kruhový uzel označený jako Π , který násobí příchozí signály z předchozí vrstvy. Výstup této vrstvy je popsán jako:

$$O_i^2 = w_i = \mu_{(Ai)}(x) \cdot \mu_{(Bi)}(y); i = 1, 2. \quad (26)$$

3. Vrstva

Každý uzel v této vrstvě je kruhový uzel označený N . Tato normalizační vrstva obdrží w_i sílu pravidla předchozí vrstvy a vypočítá normalizovanou sílu daného pravidla:

$$\bar{w}_i = \frac{w_i}{\sum_{i=1}^2 w_i}; i = 1, 2. \quad (27)$$

4. Vrstva

Každý uzel této vrstvy je adaptivní. Funkce uzlu je ve tvaru:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i); i = 1, 2, \quad (28)$$

kde O_i^4 definuje defuzzifikaci mezi vstupem a výstup této vrstvy, \bar{w}_i je síla pravidla předchozí vrstvy a p_i , q_i a r_i jsou lineární nebo konstantní adaptivní parametry nazývané také jako konsekventy.

5. Vrstva

Poslední a pevná vrstva vypočítává celkový výstup systému [3], [8] a [11].

$$O_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i \bar{w}_i f_i}{\sum_i \bar{w}_i} \quad (29)$$

4.4.2 Dávkové učení (offline)

Přestože je možné metodu gradientu použít k identifikaci parametrů v adaptivní síti, je tato metoda poměrně pomalá a je pravděpodobné, že se zachytí v lokálních minimech. Proto bylo navrženo pravidlo hybridního učení, které kombinuje metodu gradientu a odhadu nejmenších čtverců (LSE) pro identifikaci parametrů. Pro jednoduchost předpokládejme, že adaptivní síť má jeden výstup:

$$výstup = F(\vec{I}, S), \quad (30)$$

kde \vec{I} je množina vstupních proměnných a S je sada parametrů. Pokud existuje funkce H taková, že složená funkce $H \circ F$ je lineární v některých prvcích S , mohou být tyto prvky identifikovány metodou nejmenších čtverců. Jestliže množina parametrů S může být rozložena do dvou sad

$$S = S_1 \oplus S_2, \quad (31)$$

tak $H \circ F$ je lineární v prvcích S_2 , pak pro uplatnění H na (30) máme:

$$H(výstup) = H \circ F(\vec{I}, S), \quad (32)$$

který je lineární v prvcích S_2 . Vzhledem k získaným hodnotám z prvku S_1 , můžeme připojit P tréninková data do (32) a tím získat matici:

$$AX = B, \quad (33)$$

kde X je neznámý vektor, jehož prvky jsou parametry v S_1 . Necht $|S_2| = M$, pak rozměry A, X a B jsou $P \times M$, $M \times 1$ a $P \times 1$. Vzhledem k tomu, že P (počet párů tréninkových dat) je obvykle větší než M (počet lineárních parametrů) jedná se o předurčený problém a obecně neexistuje žádné přesné řešení. Namísto toho se hledá odhad nejmenších čtverců (LSE), aby se minimalizovala čtvercová chyba $\|AX - B\|^2$. Známý vzorec pro X^* využívá pseudo-inverzní X :

$$X^* = (A^t A)^{-1} A^t B \quad (34)$$

kde A^T je transponovaná A matice a $(A^T A)^{-1} A^T$ je pseudo-inverze z A , pokud $A^T A$ není singulární. Častěji se však využívají postupné vzorce pro výpočet LSE z X . Tato sekvenční metoda je účinnější a lze ji snadno změnit na online verzi pro systémy s měnícími se charakteristikami. Necht i tý řákový vektor matice A definovaný v (33) je a_i^T a i tý prvek matice B je b_i^T , pak X lze spočítat:

$$X_{i+1} = X_i + S_{i+1} a_{i+1} (b_{i+1}^T - a_{i+1}^T X_i), \quad (35)$$

$$S_{i+1} = S_i - \frac{S_i a_{i+1} a_{i+1}^T S_i}{1 + a_{i+1}^T S_i a_{i+1}}, i = 0, 1, \dots, P-1, \quad (36)$$

kde S_i je kovarianční matice a odhad nejmenších čtverců X^* je roven X_P . Počáteční podmínky jsou $X_0 = 0$ a $S_0 = \gamma I$, kde γ je kladné velké číslo a I je matice identity dimenze $M \times M$.

Nyní lze kombinovat metoda gradientu a nejmenších čtverců pro aktualizaci parametrů v adaptivní síti. Každá epocha tohoto hybridního učení se skládá z dopředného a zpětného chodu. V dopředném chodu jsou poskytnuté vstupní data a funkční signály pro výpočet každého výstupu uzlu, dokud nejsou matice A a B v (33) získány a parametry v S_2 jsou identifikovány sekvenčními nejmenšími čtvercovými vzorci. Po identifikace parametrů v S_2 funkční signály pokračují až do výpočtu míry chyb [8].

4.4.3 Vzorkové učení (online)

Pokud je požadováno, aby parametry byly aktualizovány po každé prezentaci dat, využívá se model vzorkového učení, neboli online učení. Toto učební paradigma je zásadní pro identifikaci online parametrů pro systémy s měnícími se charakteristikami. Pro změnu pravidla dávkového učení na online verzi je zřejmé, že sestupný gradient může být založen na E_p namísto E . Přesně řečeno, není to skutečně gradientní vyhledávací postup pro minimalizaci E , přesto se přiblíží k jedné, pokud je míra učení nízká. Pro sekvenční vzorce s nejmenšími čtverci, které zohledňují časově proměnné charakteristiky příchozích dat, musíme rozložit účinky starých datových párů, jakmile budou k dispozici nové páry dat. Jednou z jednodušších metod je formulovat čtvercový chybový ukazatel jako váhový převod, který dává vyšší váhové faktory novějším datovým dvojicím. To znamená přidání faktoru zapomínání X do původního sekvenčního vzorce:

$$X_{i+1} = X_i + S_{i+1} a_{i+1} (b_{i+1}^T - a_{i+1}^T X_i), \quad (37)$$

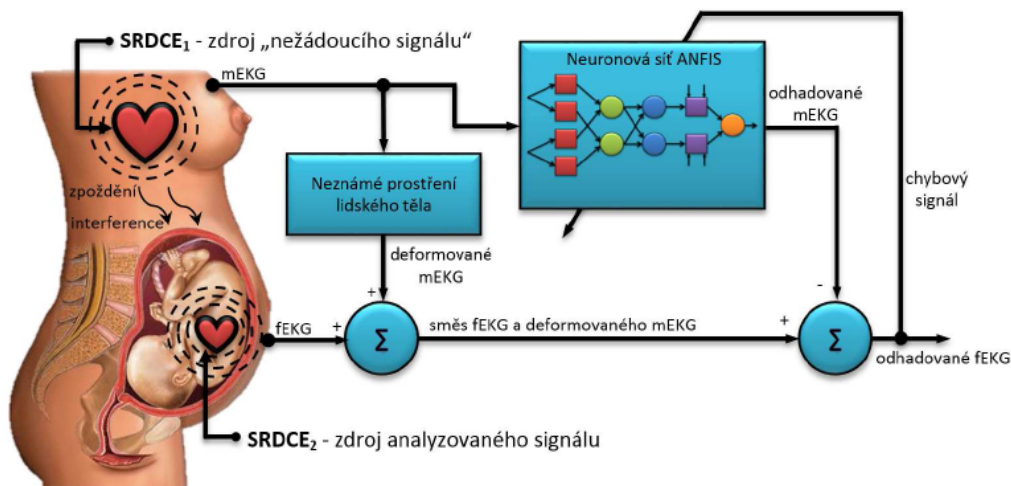
$$S_{i+1} = \frac{1}{\lambda} \left[S_i - \frac{S_i a_{i+1}^T S_i}{\lambda + a_{i+1}^T S_i a_{i+1}} \right], \quad (38)$$

kde hodnota λ je mezi 0 a 1. Čím menší je λ , tím rychlejší jsou účinky rozpadu starých dat. Naopak malá λ někdy způsobuje numerickou nestabilitu a je třeba se jí vyhnout [8].

4.4.4 Využití ANFIS pro extrakci plodového EKG

Pro extrakci fEKG jsou vyžadovány dva vstupní signály. Jedním z nich je abdominální EKG (aEKG), který je složený z mEKG a fEKG a druhý z nich je mEKG snímaný z hrudníku matky. Signál snímaný z hrudníku matky slouží jako referenční signál, zatímco mEKG je náš požadovaný signál. ANFIS iniciuje proces učení, který přizpůsobuje jeho parametry, dokud nedosáhne požadovaného počtu epoch nebo dokud nebude dostatečně "vycvičen". Výstup adaptivního neuro-fuzzy inferenčního systému se pak odhadne na mEKG z abdominálního signálu. Chyba mezi požadovaným a odhadovaným mEKG nám dává signál fEKG. Principiální schéma extrakce je zobrazeno na Obrázku 13 [11].

Jak lze na Obrázku 13 pozorovat, snímané mEKG z břicha matky bude, oproti mEKG snímané z hrudníku, deformované. To je způsobeno průchodem daného signálu neznámým prostředím lidského těla a zároveň dochází ke zpoždění tohoto signálu. Z toho důvodu nelze získat fEKG lineárními metodami. Problém s nelinearitou tohoto signálu řeší adaptivní neuro-fuzzy inferenční systém, který se adaptuje na mEKG snímané z hrudníku. Na základě této adaptace je pak systém schopný rozpoznat tento signál snímaný z břicha matky. Po naučení mEKG z hrudníku do systému vstupuje aEKG, které obsahuje náš požadovaný signál fEKG a zároveň deformované mEKG. Posledním krokem toho systému je odfiltrování mEKG z aEKG. Tím získáme naše požadované fEKG.



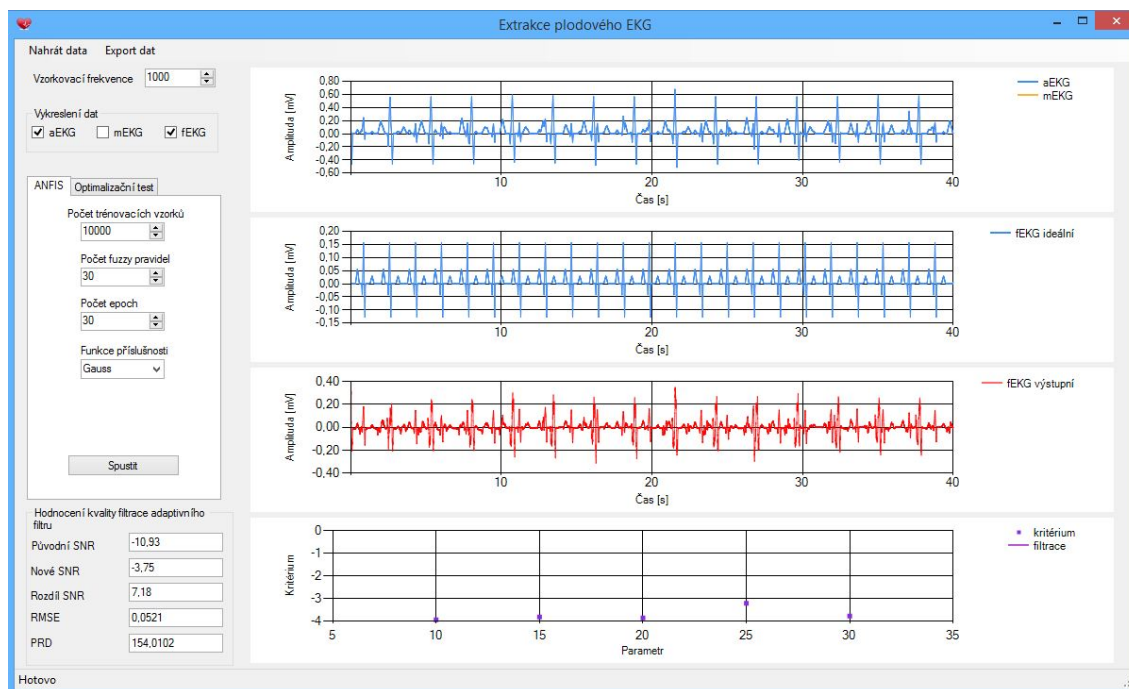
Obrázek 13: Zjednodušené principiální schéma systému ANFIS pro extrakci fEKG (převzato z [3])

5 Návrh a implementace softwarového rozhraní

Tato kapitola se zabývá návrhem a implementací softwarového rozhraní pro extrakci plodového EKG pomocí adaptivního neuro-fuzzy inferenčního systému. Je zde popsáno grafické rozhraní uživatele (GUI) a jednotlivé funkce softwaru, který byl vytvořen v aplikaci Visual Studio 2015 od Microsoftu v programovacím jazyce C#.

5.1 GUI

Navržený program je rozdělen na dvě části. V levé části je nastavení parametrů, včetně zobrazení hodnocení kvality filtrace, které je popsáno níže. V pravé části jsou umístěny 4 grafy. V prvním grafu je možné zobrazit signál mEKG a aEKG. V dalším je možné vykreslit signál ideálního fEKG (v případě, že pracujeme se syntetickými daty). Pro vykreslení výstupu adaptivního systému je určen následující graf. Poslední graf slouží k zobrazení optimalizačního testu, který je popsán v další části. Grafické rozhraní vytvořené aplikace je zobrazeno na Obrázku 14.



Obrázek 14: Grafické rozhraní implementovaného softwaru


5.2 Popis jednotlivých funkcí softwaru

V této části jsou popsány jednotlivé funkce vytvořeného softwaru, jako je import a export dat, využití adaptivního neuro-fuzzy inferenčního systému, popis optimalizačního testu a možnosti jednotlivých grafů. Vývojový diagram implementovaného softwarového rozhraní je zobrazen na Obrázku 18.

5.2.1 Import dat, vykreslení a následný export

Aby bylo možné dále pracovat se softwarem, je nejdříve nutné nahrát data. V levém menu v záložce nahrát můžeme nahrát tři signály, mEKG, aEKG a fEKG. Pro práci s adaptivním filtrem postačí nahrát pouze signál matčina a abdominálního EKG. Tato možnost se využívá pro práci s reálnými daty. V případě, že pracujeme s daty syntetickými, je nutné nahrát signál ideálního plodového EKG. V případě, že je tento signál nahrán, lze získat informace o kvalitě filtrace a lze pracovat s optimalizačním testem, popsaným níže.

Pro vykreslení importovaných dat je potřebné zadat vzorkovací frekvenci, abychom získali přesnou informaci o časovém průběhu daného signálu, a zaškrtnout daný signál v připraveném checkboxu. Vykreslená data v grafech lze přiblížit pomocí najetí myše na daný graf a použití kolečka. V tu chvíli proběhne přiblížení na ose x a y a objeví se posuvníky. Funkce přiblížení je zobrazena na Obrázku 15. Pokud není třeba přiblížení na určité ose, mají v sobě posuvníky naimplementované tlačítko, které slouží k ukotvení dané osy.



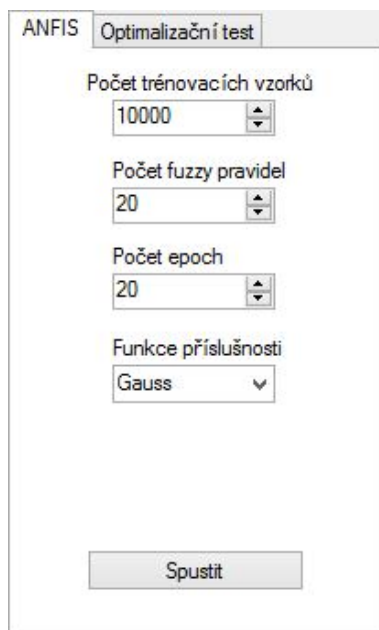
Obrázek 15: Zobrazení posuvníků v grafu s ukotvenou osou y

Signál získaný z adaptivního filtru a hodnoty získané z optimalizace je možné exportovat do textového souboru. Implementace uložení dat je založena na metodě `SaveFileDialog`, což znamená, že daná data je možno uložit na libovolné místo na disku.

5.2.2 ANFIS

Pro spuštění adaptivního neuro-fuzzy inferenčního systému je potřeba zadat vstupní parametry systému, jakou jsou počet trénovacích vzorků, počet fuzzy pravidel, počet epoch a funkci příslušnosti. Rozhraní pro spuštění systému je zobrazeno na Obrázku 16. Počet trénovacích vzorků musí být větší než nula. v případě, že je počet větší než délka signálu, bude ANFIS pracovat s maximálním možným počtem vzorků, který je roven délce daného signálu.

Dalším parametrem nutným ke spuštění je počet fuzzy pravidel a počet epoch, neboli iterací, které musí být větší než 0. Velikost těchto parametrů ovlivňuje výpočetní náročnost systému a tím i jeho délku. Posledním parametrem, který je potřeba zadat je tvar funkce příslušnosti. v systému jsou implementovány dvě funkce a to Gaussova a zvonová. Jejich průběhy jsou zobrazeny na Obrázku 4.



The image shows a software window titled 'ANFIS Optimalizační test'. Inside, there are four labeled input fields, each with a numeric spinner control. The first field is 'Počet trénovacích vzorků' with the value 10000. The second is 'Počet fuzzy pravidel' with the value 20. The third is 'Počet epoch' with the value 20. The fourth is 'Funkce příslušnosti' with a dropdown menu showing 'Gauss'. At the bottom of the window is a button labeled 'Spustit'.

Obrázek 16: Rozhraní pro spuštění adaptivního systému

Po spuštění se ve spodní liště zobrazí ukazatel průběhu, který poběží až do doby, než bude funkce adaptivního systému ukončena. Ve stejném okamžiku se ve třetím grafu zobrazí výstup tohoto systému, tedy naše odhadované plodové EKG.

5.2.3 Optimalizační test

Optimalizace slouží k nalezení optimálních parametrů systému ANFIS v závislosti na daném kritériu. Prvním krokem je výběr parametru. Na výběr jsou 3 možnosti:

- počet trénovacích vzorků,
- počet fuzzy pravidel,
- počet epoch.

V případě výběru jedné z těchto možností se další parametry získají z okna ANFIS popsaného výše. Dalším požadavkem na optimalizaci je výběr jednoho z kritérií, a to SNR, RMSE a PRD.

Posledním krokem pro nastavení optimalizace je počáteční a koncová hodnota s daným krokem. Prostředí optimalizace je na Obrázku 17. Po zadání parametru a kritéria je možné spustit samotnou optimalizaci. Ta probíhá ve vláknech, tzn., že pro každý nastavený parametr se spustí jedno vlákno adaptivního systému. Poté co všechna vlákna dokončí svou práci, je vykreslen graf závislosti parametru na daném kritériu.

ANFIS Optimalizační test

Optimalizační parametr
Epochy

Optimalizační kritérium
SNR

Počáteční hodnota
10

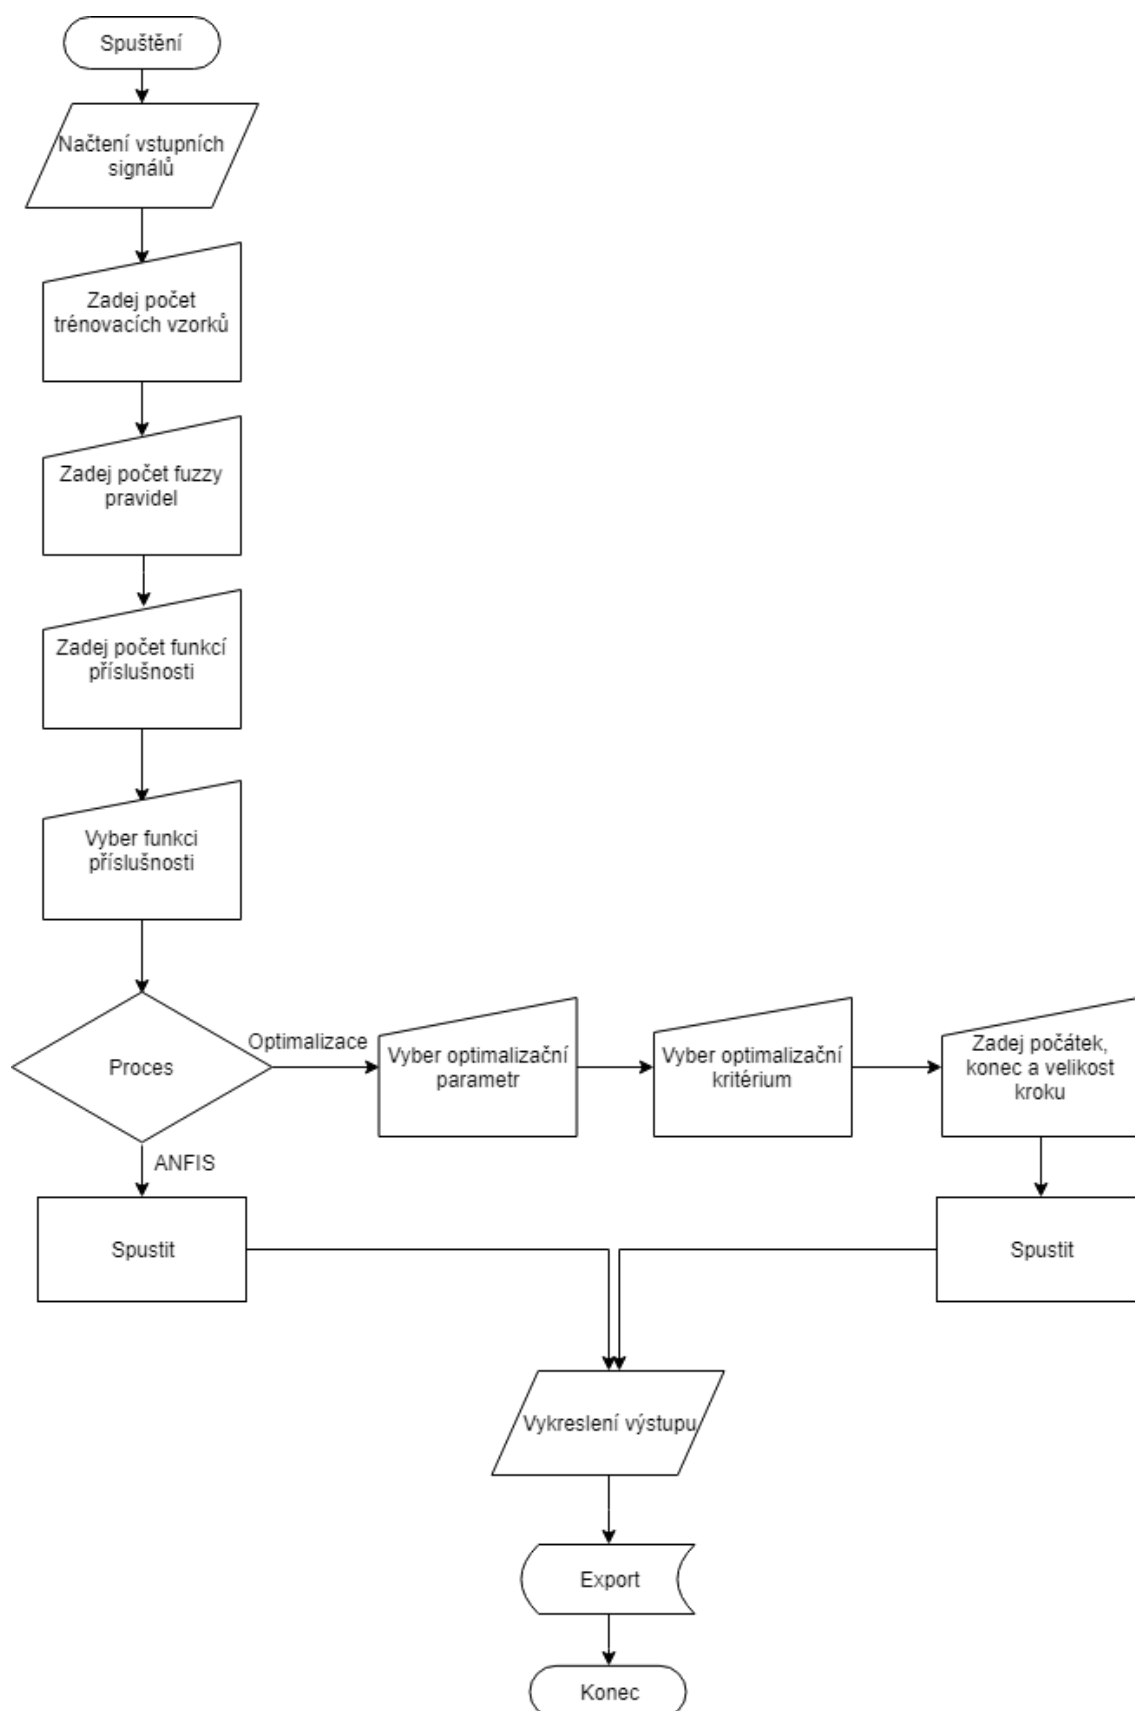
Koncová hodnota
30

Velikost kroku
5

Počet trénovacích vzorků: 10000
Počet fuzzy pravidel: 20
Počet epoch:
Max. hodnota kritéria: 11,15
Min. hodnota kritéria: 9,8

Spustit

Obrázek 17: Rozhraní pro spuštění optimalizace



Obrázek 18: Vývojový diagram

5.3 Metody hodnocení kvality filtrace

Jedním ze zásadních problémů pro hodnocení kvality extrakce plodového EKG je obtížnost při poskytování objektivních měřítek kvality získaných signálů. To je jeden z důvodů, proč se velmi často přistupuje k subjektivním metodám hodnocení (vizuální hodnocení). V této práci bylo použito tří metod pro hodnocení kvality extrahovaného signálu a to:

- odstup signál od šumu (SNR - signal to noise ratio),
- relativní střední kvadratická chyba (RMSE - root mean square error),
- procentuální rozdíl střední kvadratické chyby (PRD - percent root mean square difference).

Blíže jsou tyto metody hodnocení kvality popsány v následujících podkapitolách.

5.3.1 SNR

Parametr SNR definuje vztah mezi signálem a šumem. Aby bylo možné tento parametr využít pro hodnocení kvality, je nezbytné určit jeho hodnotu před filtrací (SNR_{vst}) a po filtraci ($SNR_{výst}$). Hodnotu (SNR_{vst}) spočítáme pomocí následující rovnice:

$$SNR_{vst} = 10 \cdot \log_{10} \frac{\sum_{n=1}^{N-1} [sig_{užit}(n)]^2}{\sum_{n=1}^{N-1} [sig_{ruš}(n) - sig_{užit}(n)]^2}, \quad (39)$$

kde $sig_{užit}(n)$ je užitečný signál (v našem případě ideální fEKG) a $sig_{ruš}(n)$ je rušivý signál (mEKG po průchodu neznámým prostředím lidského těla). Protože je rušivý signál tvořen součtem fEKG a mEKG, je nezbytné od rušivého signálu odečíst signál užitečný.

K dalšímu hodnocení je potřeba znát $SNR_{výst}$. To získáme při dosazení do následující rovnice:

$$SNR_{výst} = 10 \cdot \log_{10} \frac{\sum_{n=1}^{N-1} [sig_{užit}(n)]^2}{\sum_{n=1}^{N-1} [sig_{predik}(n) - sig_{užit}(n)]^2}, \quad (40)$$

kde sig_{predik} je predikovaný signál, tedy výstup z adaptivního systému [3].

5.3.2 PRD

Hodnocení kvality extrakce fEKG jsou založeny na podobnosti predikovaných a původních signálů. V této práci bylo použito k porovnání podobnosti metody procentuálního rozdílu střední kvadratické chyby, jejíž hodnotu spočítáme pomocí následujícího vztahu:

$$PRD = \sqrt{\frac{\sum_{n=1}^N [sig_{ideal}(n) - sig_{predik}(n)]^2}{\sum_{n=1}^N sig_{ideal}^2(n)}} \cdot 100[\%], \quad (41)$$

kde $sig_{ideal}(n)$ je signál ideálního plodového EKG a $sig_{predik}(n)$ je signál získaný pro průchodu adaptivním systémem. z pravidla platí, že čím více se hodnota PRD blíží k nule, tím více si jsou signály podobné [22], [23].

5.3.3 MSE a RMSE

Poslední metody představené v této práci jsou Mean square error (MSE) a její varianta Root mean square error, pomocí nichž lze měřit kvalitu predikce tzv. predikční chybou. Ta vyjadřuje míru nepřesnosti mezi predikovaným a ideálním výstupem. MSE poskytuje informaci o velikosti průměrného rozdílu mezi korespondujícími vzorky obou signálů, viz rovnice (42).

$$MSE = \frac{1}{n} \sum_{n=1}^N (sig_{ideal} - sig_{predik})^2. \quad (42)$$

V praxi je však tento vztah často nahrazován RMSE chybou, která je odmocninou MSE chyby, viz rovnice (43).

$$RMSE = \sqrt{\frac{1}{n} \sum_{n=1}^N (sig_{ideal} - sig_{predik})^2}. \quad (43)$$


V obou případech platí, že sig_{ideal} je signál ideálního plodového EKG a sig_{predik} je signál získaný z výstupu adaptivního filtru. Jako u metody PRD platí, že čím více se hodnota RMSE blíží k nule, tím lépe predikovaný signál odpovídá ideálnímu signálu [3], [24].

6 Testování adaptivního filtru pro extrakci plodového EKG

Tato část diplomové práce je věnována testování adaptivního filtru pro extrakci fEKG pomocí různých signálů. Pro experiment byly vybrány tři druhy signálu, jednoduchá syntetická data, složitější syntetická data a reálná data. Tyto signály jsou blíže popsány v následujících podkapitolách.

6.1 Jednoduchá syntetická data

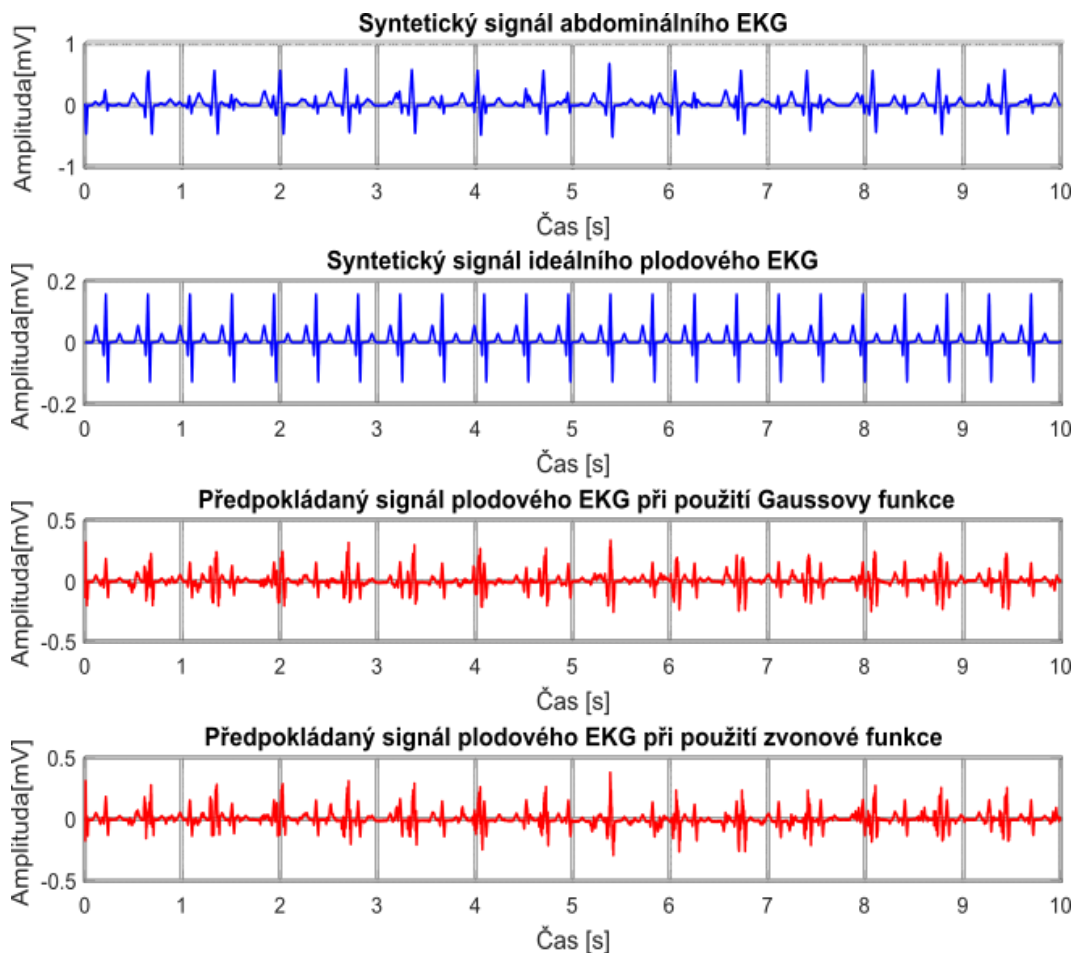
První část testování implementovaného filtru byla provedena na jednoduchých syntetických datech, které vytvořila Ing. Radana Kahánková ve své diplomové práci, kterou lze nalézt v [20]. Tyto signály byly vygenerovány v softwarovém prostředí Matlab. Nejdříve byly vytvořeny signály mEKG, tedy EKG snímané z hrudníku matky, a EKG plodu. Abdominální signály byly poté zhotoveny z ideálního průběhu EKG plodu a hrudních signálu matky, které byly následně zpožděny pomocí FIR filtru 50. řádu. Tímto byl napodoben průchod EKG signálu matky od srdce k břišní stěně. Na Obrázku 19 jsou tyto signály vykresleny.



Obrázek 19: Jednoduché syntetické signály

6.1.1 Výsledky adaptivního filtru při použití jednoduchých syntetických dat

V experimentální části bylo jako první testování adaptivního filtru provedeno na jednoduchých syntetických datech. Na Obrázku 20 je vykreslen výstup adaptivního filtru při 50 epochách a 50 fuzzy pravidel pro různé účelové funkce (Gaussova a zvonová).



Obrázek 20: Výstup adaptivního systému při použití jednoduchých syntetických dat

Na základě vizuálního hodnocení adaptivního filtru sice došlo k částečnému potlačení mEKG ze zarušeného abdominálního EKG, avšak amplituda matky stále převažuje nad amplitudou EKG plodu. Přestože nedošlo k úplnému potlačení QRS komplexu matky, lze z výstupu identifikovat QRS komplex plodu.


V Tabulce 2 lze nalézt hodnoty SNR, RMSE a PRD v závislosti na počtu epoch a počtu fuzzy pravidel při použití jedné ze dvou účelových funkcí. Při tomto experimentu bylo použito plného počtu vzorků jako trénovacích, v našem případě 40 000 vzorků.

Tabulka 2: Tabulka hodnot pro jednoduchá syntetická data


		Gauss			Zvonová		
Epochy	Pravidla	SNR [dB]	RMSE [-]	PRD [%]	SNR [dB]	RMSE [-]	PRD [%]
10	10	-4,09	0,0552	160	-4,26	0,0563	163
10	20	-3,99	0,0545	158	-3,99	0,0545	158
10	30	-3,80	0,0534	155	-3,78	0,0533	155
10	40	-3,79	0,0533	155	-3,96	0,0544	158
10	50	-3,78	0,0532	154	-3,66	0,0525	152
20	10	-4,07	0,0551	160	-4,11	0,0553	160
20	20	-3,62	0,0523	152	-3,95	0,0543	158
20	30	-3,81	0,0534	155	-3,49	0,0515	149
20	40	-3,65	0,0525	152	-3,10	0,0492	143
20	50	-3,28	0,0503	146	-2,76	0,0473	137
30	10	-3,93	0,0542	157	-4,05	0,0550	159
30	20	-3,55	0,0519	151	-3,39	0,0509	148
30	30	-3,34	0,0506	147	-3,42	0,0511	148
30	40	-3,07	0,0491	142	-3,02	0,0488	142
30	50	-3,51	0,0516	150	-2,74	0,0472	137
40	10	-3,98	0,0545	158	-3,99	0,0546	158
40	20	-3,77	0,0532	154	-3,35	0,0507	147
40	30	-3,49	0,0515	150	-2,57	0,0463	134
40	40	-2,96	0,0484	141	-2,35	0,0452	131
40	50	-3,04	0,0489	142	-3,50	0,0516	150
50	10	-3,62	0,0523	152	-4,15	0,0556	161
50	20	-3,96	0,0544	158	-4,60	0,0585	170
50	30	-3,05	0,0490	142	-1,40	0,0405	117
50	40	-3,50	0,0515	150	-2,54	0,0462	134
50	50	-2,23	0,0445	129	-1,45	0,0407	118

Původní SNR těchto signálů bylo -10,93 dB. z toho vyplývá, že po průchodu dat adaptivním systémem bylo dosaženo zlepšení o více než 9 dB. Hodnoty PRD u obou účelových funkcí neklesly pod hodnotu 100%. Relativní střední kvadratická chyba nebyla nižší než 0,0405. Z výsledků uvedených v Tabulce 2 lze předpokládat, že pro uvedené signály dosahuje o něco lepších hodnot použití ANFIS se zvonovou funkcí.

Na Obrázku 21 a 22 jsou vykresleny 3D grafy závislosti SNR na počtu epoch a počtu fuzzy pravidel. z Obrázku 18 je zřejmé, že při zvyšování těchto parametrů bylo dosaženo lepšího odstupu signálu od šumu. Lze také pozorovat snížení hodnoty SNR při 40 epochách a 50 pravidlech a naopak. Toto snížení je pravděpodobně způsobené špatnou adaptací systému na vstupní signály. U obou grafů lze vypořizovat, že maximální hodnoty SNR bylo dosaženo právě při použití 50 epoch a 50 fuzzy pravidel.




Obrázek 21: 3D graf závislosti SNR na počtu epoch a počtu fuzzy pravidel při použití zvonové funkce




Obrázek 22: 3D graf závislosti SNR na počtu epoch a počtu fuzzy pravidel při použití Gaussovy funkce

Další metodou hodnocení výstupu ANFIS bylo zjištění závislosti daných kritérií na počtu trénovacích vzorků. Tato závislost je zobrazena na Obrázku 23 a 24. Z Obrázku 23 je patrné, že při použití 10 epoch a 10 fuzzy pravidel, počet trénovacích vzorků měl jen nepatrný vliv na hodnoty daných kritérií. U ostatních parametrů lze pozorovat zlepšení daných kritérií při zvětšujícím se počtu vzorků.



Obrázek 23: Grafy závislosti daných kritérií na počtu trénovacích vzorků při použití zvonové funkce

Na Obrázku 24 lze vypořizovat, že při použití 24 000 trénovacích vzorků došlo k adaptaci systému srovnatelné s použitím plného počtu vzorků. Taktěž se opakuje téměř nezávislost na počtu trénovacích vzorků při použití 10 epoch a 10 fuzzy pravidel.




Obrázek 24: Grafy závislosti daných kritérií na počtu trénovacích vzorků při použití Gaussovy funkce

6.2 Složitější syntetická data

Na testování adaptivního neuro-fuzzy inferenčního systému pro extrakci plodového EKG byly použity i složitější syntetické signály. Tyto signály jsou získány z generátoru plodového EKG představeného v práci R. Martinka a kolektivu v [21]. Výhodou tohoto generátoru je možnost nastavení mnoha parametrů, jako je tepová frekvence plodu a matky, gestační věk plodu, různé rušení plodového EKG (biologické a technické artefakty) a další. Zároveň je možné z generátoru získat syntetický signál s definovanými vlastnostmi pro 6 svodů.


Pro experimenty v této práci mají takto vytvořené signály velkou váhu. Díky svému charakteru jsou velice podobné reálným signálům, a zároveň díky možnosti získání ideálního fEKG lze hodnotit kvalitu filtrace pomocí metod popsanych v podkapitole 5.3. Rozdíl mezi signály popsanými v podkapitole 8.1 a signály získanými z generátoru je jejich charakter zkraslení. Zatímco u jednoduchých syntetických dat bylo ke zkraslení využito FIR filtru, který je funkcí lineární, signály získané z generátoru simulují průchod tělem matky pomocí nelineární funkce. Na základě těchto informací je předpoklad, že při průchodu těchto signálů systémem ANFIS bude dosaženo lepších výsledků než v předchozí kapitole, protože ANFIS lépe pracuje s daty s nelineárním charakterem. Ukázka takto vygenerovaných dat je vyobrazena na Obrázku 25.



Obrázek 25: Syntetické signály z generátoru

6.2.1 Výsledky adaptivního filtru při použití složitějších syntetických dat

Extrakce plodového EKG ze signálů získaných z generátorů byla oproti jednodušším syntetickým signálům mnohem efektivnější. Jak je vidět na Obrázku 26 systém extrahoval fEKG a dostatečně potlačil šum mEKG. Při porovnání předpokládaného signálu plodového EKG při použití Gaussovy a zvonové funkce, lze vypožorovat, že v tomto případě je podstatně kvalitnější výstup při použití Gaussovy funkce.



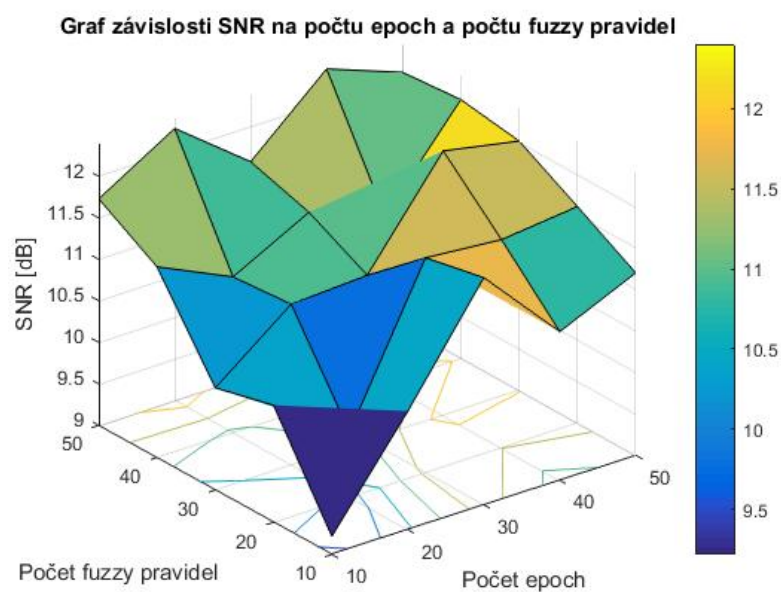
Obrázek 26: Výstup adaptivního systému při použití jednoduchých syntetických dat

Při porovnání hodnot v Tabulce 3 je zřejmé, že kvalitnější výstup při použití Gaussovy funkce není pouze vizuální předpoklad. Původní odstup signálu od šumu je -13,24 dB. Při použití Gaussovy funkce bylo dosaženo hodnot SNR přesahujících 12 dB. Z těchto údajů vyplývá, že rozdíl odstup signálu od šumu od původního signálu je přibližně větší o 20 dB. Nejnížší hodnota RMSE byla dosažena při 50 epochách a 40 fuzzy pravidlech a to 0,0096. Při stejných parametrech bylo dosaženo nejnížší hodnoty PRD 24%. Na základě těchto výsledků lze potvrdit předpoklad, že na těchto složitějších datech bude systém ANFIS mnohem efektivnější.


Tabulka 3: Tabulka hodnot pro jednoduchá syntetická data

		Gauss			Zvonová		
Epochy	Pravidla	SNR [dB]	RMSE [-]	PRD [%]	SNR [dB]	RMSE [-]	PRD [%]
10	10	9,22	0,0138	34,6	4,82	0,0229	57,4
10	20	10,43	0,0120	30,1	8,60	0,0149	37,2
10	30	11,74	0,0103	25,9	9,32	0,0137	34,2
10	40	10,79	0,0115	28,9	9,16	0,0139	34,8
10	50	11,20	0,0110	27,5	10,49	0,0120	29,9
20	10	10,41	0,0121	30,2	6,62	0,0187	46,7
20	20	9,79	0,0130	32,4	9,41	0,0135	33,9
20	30	11,59	0,0105	26,3	9,96	0,0127	31,8
20	40	11,51	0,0106	26,6	10,16	0,0124	31,0
20	50	11,61	0,0105	26,3	10,56	0,0119	29,7
30	10	10,23	0,0123	30,8	6,91	0,0180	45,1
30	20	10,94	0,0113	28,4	9,91	0,0128	31,9
30	30	10,99	0,0113	28,2	10,20	0,0123	30,9
30	40	12,19	0,0098	24,6	9,83	0,0129	32,3
30	50	12,01	0,0100	25,1	10,14	0,0124	31,1
40	10	11,30	0,0105	30,1	6,97	0,0179	44,8
40	20	10,88	0,0112	28,0	9,27	0,0137	34,4
40	30	11,36	0,0109	25,3	10,47	0,0120	30,0
40	40	11,02	0,0101	27,3	10,25	0,0123	30,7
40	50	12,12	0,0104	25,7	10,79	0,0115	28,9
50	10	11,73	0,0104	25,9	8,77	0,0146	36,4
50	20	12,28	0,0097	24,3	9,36	0,0136	34,0
50	30	11,58	0,0105	26,4	10,69	0,0117	29,2
50	40	12,40	0,0096	24,0	10,68	0,0117	29,3
50	50	12,06	0,0100	24,9	10,10	0,0125	31,3

Závislost odstupů signálu od šumu na počtu epoch a počtu fuzzy pravidel zobrazuje Obrázek 27 a 28. Opět lze pozorovat nárůst SNR se zvyšujícími se hodnotami zvolených parametrů. Taktéž je zřejmé, že nárůst není lineární a velmi záleží na samotné adaptaci systému na vstupní data. V porovnání s přechovými jednoduchými syntetickými daty však bylo dosaženo zlepšení SNR o více než 20 dB. Pro tyto experimenty bylo opět pracováno s plným počtem vzorků, tedy s 10 000 vzorky.




Obrázek 27: 3D graf závislosti SNR na počtu epoch a počtu fuzzy pravidel při použití Gaussovy funkce

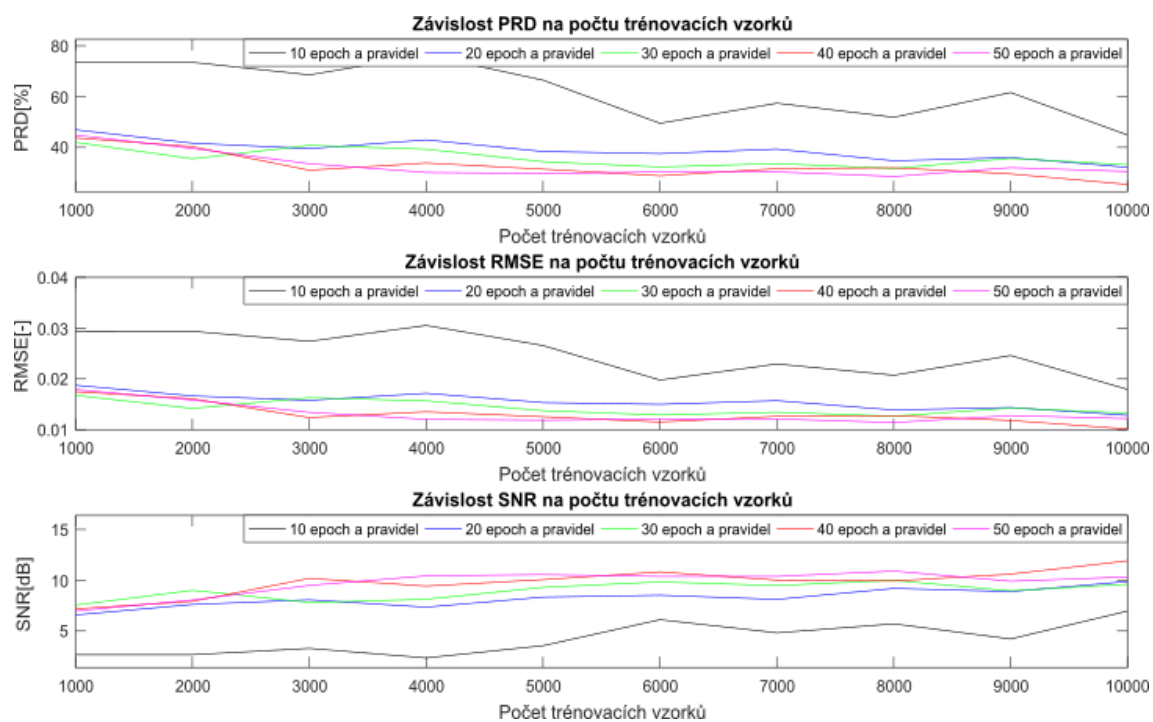


Obrázek 28: 3D graf závislosti SNR na počtu epoch a počtu fuzzy pravidel při použití zvonové funkce

Dalším kritériem hodnocení na těchto signálech bylo srovnání kvality filtrace při použití různých počtu trénovacích vzorků. Závislost daných kritérií na počtu trénovacích vzorků je uvedena na Obrázku 29 a 30. Z grafů níže je patrné, že existuje závislost kvality filtrace na počtu trénovacích vzorků. Za zmínku ovšem stojí, že od poloviny celkového počtu vzorků již rozdíl kvality není tolik významný. Toto tvrzení však neplatí při použití 10 epoch a 10 fuzzy pravidel.



Obrázek 29: Grafy závislosti daných kritérií na počtu trénovacích vzorků při použití Gaussovy funkce



Obrázek 30: Grafy závislosti daných kritérií na počtu trénovacích vzorků při použití zvonové funkce

6.3 Reálná data


Použitá reálná data v této práci byla získána z databáze neinvazivních fEKG záznamů PhysioNet [25]. Tato databáze obsahuje sérii 55 vícekanálových neinvazivních záznamů fetálního elektrocardiogramu, které byly získány od jediného subjektu v období 21. až 40. týdnu těhotenství. Záznamy mají proměnné trvání a byly snímány alespoň jednou týdně. Naměřená data byla uložena do formátu EDF/EDF+.

Podrobnější informace o záznamech:

- 2 hrudní a 3 nebo 4 abdominální signály (většina záznamů obsahuje 4 abdominální signály),
- umístění elektrod bylo proměnlivé v závislosti na zlepšení odstupu signálu od šumu,
- analogový zesilovač s notch filtrem (odstranění síťového brumu 50 Hz),
- šířka pásma v rozmezí 0,01-100 Hz,
- vzorkovací frekvence vždy 1 kHz,
- rozlišení 16 bitů.


6.3.1 Výsledky adaptivního filtru při použití reálných dat

U reálných signálů již není možné použít objektivní hodnocení, z důvodu chybějícího ideálního průběhu fetálního EKG. Proto výstupy adaptivního systému byly zhodnoceny pouze subjektivně. Toto hodnocení může mít však svá úskalí, neboť interpretovaná data mohou být špatně posouzena a vyhodnocena pozorovatelem. Vstupní signály do adaptivního systému jsou zobrazeny na Obrázku 31.




Obrázek 31: Vstupní reálná data

Pro subjektivní hodnocení byly použity různé parametry systému ANFIS. Prvním z nich je nastavení 20 epoch a 20 fuzzy pravidel. Výsledek po průchodu adaptivním systémem je na Obrázku 32. Při použití Gaussovy funkce bylo dosaženo lepšího potlačení mateřského EKG oproti použití funkce zvonové. Zároveň u obou případů došlo k zúžení QRS komplexu. Přesto není potlačení dostačující pro analýzu plodového EKG.




Obrázek 32: Výstup adaptivního systému při použití 20 epoch a 20 fuzzy pravidel

Další nastavení systému ANFIS probíhalo při použití 30 epoch a 30 fuzzy pravidel. Jak je z Obrázku 33 patrné, systém ANFIS při použití Gaussovy funkce dosahuje mnohem lepšího potlačení mateřského EKG než zvonová funkce. Na tomto výstupu již lze v určitých místech identifikovat QRS komplex plodu.




Obrázek 33: Výstup adaptivního systému při použití 30 epoch a 30 fuzzy pravidel

Oproti předchozímu nastavení, výstup při 40 epochách a 40 fuzzy pravidlech vykazuje zlepšení i při použití zvonové funkce. Avšak opět platí, že Gaussova dosahuje lepších hodnot. Na Obrázku 34 lze vyzorovat, že amplituda mateřského EKG dosahuje téměř stejné velikosti jako amplituda plodového EKG. Toto tvrzení ovšem platí pouze při použití Gaussovy funkce.



Obrázek 34: Výstup adaptivního systému při použití 40 epoch a 40 fuzzy pravidel

Posledními vstupními parametry použitými na reálná data bylo nastavení 50 epoch a 50 fuzzy pravidel. Jak je na Obrázku 35 vidět, při tomto nastavení dokázal ANFIS potlačit mEKG i při využití zvonové funkce příslušnosti. Na těchto výstupech lze z velké části identifikovat plodové EKG, avšak signál je stále degradován množstvím biologických artefaktů.



Obrázek 35: Výstup adaptivního systému při použití 50 epoch a 50 fuzzy pravidel

7 Zhodnocení výsledků

Tato kapitola je zaměřena na zhodnocení výsledků provedených experimentů. Jako testovaná data byly použity jednoduché signály, složitější a reálné. Během experimentů bylo zkoumáno nastavení jednotlivých parametrů a jejich vliv na výsledný vyfiltrovaný signál. Těmito parametry byly:

- počet trénovacích vzorků,
- počet epoch,
- počet fuzzy pravidel,
- typ funkce příslušnosti (Gaussova a zvonová).

První signály použity pro testování adaptivního systému byly jednoduchá syntetická data vytvořená v Matlabu, kde zkreslení signálů bylo dosaženo pomocí FIR filtru 50. řádu. Dle hodnot kritérií uvedených v Tabulce 2 bylo dosaženo lepších výsledků při použití adaptivního systému se zvonovou funkcí příslušnosti. Přesto však nedošlo k dostatečnému odstranění mateřské složky. Amplituda mEKG dosahovala vyšších hodnot než amplituda fEKG. Avšak po průchodu těchto signálů adaptivním systémem došlo k zúžení QRS komplexu matky. Neúspěšnost filtrace na tomto vstupu lze vysvětlit určitou linearitou daných signálů, neboť ANFIS mnohem lépe pracuje s nelinearitami. Dále byla zkoumána závislost kvality filtrace na počtu epoch a počtu fuzzy pravidel při použití plného počtu vzorků (40 000). Kvalita filtrace byla hodnocena pomocí SNR, RMSE a PRD. Z těchto výsledků lze říct, že na kvalitu filtrace má mnohem větší vliv počet fuzzy pravidel. Poslední část byla zaměřena na závislosti daných kritérií na použití počtu vzorků. Pro nastavení deseti epoch a deseti fuzzy pravidel nemělo navyšování počtu vzorků téměř žádný vliv. U vyšších hodnot daných parametrů docházelo se zvyšováním vzorků lepších výsledků.

Následně proběhlo testování se složitějšími signály s reálným charakterem, získanými z generátoru plodového EKG. Zkreslení těchto dat bylo provedeno pomocí nelineární funkce. Oproti jednoduchým signálům bylo u složitějších dosaženo kvalitnější filtrace při použití Gaussovy funkce příslušnosti. Pro nejnižší nastavené parametry (10 epoch a 10 fuzzy pravidel) bylo SNR o necelých 5 dB větší v porovnání se zvonovou funkcí. Po průchodu dat adaptivním systémem došlo k téměř úplnému potlačení mateřské složky. Při porovnání závislosti kritérií, při použití plného počtu vzorků (10 000), na počtu epoch a počtu fuzzy pravidel, lze sledovat nárůst hodnot při zvyšování daných parametrů. Závislost kvality filtrace na použitém počtu vzorků byla také zkoumána. Největší závislost byla zřejmá při použití deseti epoch a deseti fuzzy pravidel, u vyšších hodnot parametrů, od poloviny použitých trénovacích vzorků, již další navyšování ne-

mělo zásadní vliv. Toto zjištění může do budoucna posloužit při požadavku na snížení výpočetní náročnosti daného adaptivního systému a s tím souvisejícím časem filtrace.

Jako poslední byly testovány reálné signály získané z databáze PhysioNet. Vzhledem k chybějící informaci o ideálním průběhu plodového EKG již nebylo možné hodnotit kvalitu filtrace pomocí kritérií SNR, PRD a RMSE. Proto bylo v této části přistoupeno pouze k subjektivnímu hodnocení. Jako u předchozích dat došlo k lepší filtraci vstupního signálu při použití Gaussovy funkce. Již při použití třiceti epoch a třiceti fuzzy pravidel bylo dosaženo potlačení mEKG téměř o polovinu. Pro nastavení padesáti epoch a fuzzy pravidel došlo v určitých místech k úplnému potlačení mateřské složky. Avšak přesto nebylo možné v celém signálu stoprocentně určit fetální EKG, neboť signál je stále degradován množstvím biologických signálů. Pro získání kvalitnějších výsledků by do budoucna bylo vhodné zařadit blok předzpracování plodového EKG, aby došlo k odstranění těchto artefaktů. Je třeba zmínit, že kvalitu těchto signálů ovlivňuje i umístění elektrody v abdominální oblasti. Proto by bylo vhodné umístit elektrod co nejbližší ke zdroji požadovaného signálu.

8 Závěr

Cílem této diplomové práce byla realizace softwarového rozhraní využívající adaptivní neuro-fuzzy inferenční systém pro extrakci plodového EKG a ověření funkčnosti implementovaného systému na syntetických a reálných datech.

Jako první signály pro testování daného systému byly vybrány jednoduché syntetické data. ANFIS však nebyl schopný s těmito daty pracovat zcela správně a po filtraci došlo pouze ke snížení amplitudy mEKG a zúžení QRS komplexu matky. Toto chování lze vysvětlit určitou linearitou dat, zatímco ANFIS je sestaven právě pro práci s nelinearitami. U těchto dat systém vykazoval lepších výsledků při použití zvonové funkce příslušnosti. Při použití složitějších syntetických signálů s reálným charakterem však bylo dosaženo překvapivých výsledků. Mateřské EKG bylo téměř stoprocentně potlačeno a tím byla získána informace o průběhu plodového EKG. Také bylo zjištěno, že mnohem lepších výsledků dosahoval ANFIS při použití Gaussovy funkce. Jako poslední byla testována reálná data. I u těchto signálů dosahoval ANFIS lepších výsledků při použití Gaussovy funkce. Po průchodu dat adaptivním filtrem došlo k potlačení mateřského EKG, avšak získané informace o průběhu plodového EKG nebyly zcela ideální. Výstupní signál byl stále degradován množstvím biologických artefaktů. I přesto však ve velké části signálu bylo možno detekovat QRS komplex plodu.

Přínosem této práce bylo zjištění, že pro kvalitní výstupy systému není třeba použít plného počtu trénovacích vzorků, což může být použito při požadavku na snížení výpočetní náročnosti a s tím souvisejícím časem zpracování vstupních signálů. Dále je třeba vyzdvihnout účinnost implementovaného adaptivního systému při použití s reálnými daty. Avšak pro získání kvalitnějších výstupů by do budoucna bylo vhodné zařadit blok předzpracování, který by eliminoval rušivé biologické artefakty. Pro použití v klinické praxi by bylo příhodné umístit elektrodu v abdominální oblasti co nejblíže ke zdroji požadovaného signálu, aby bylo dosaženo co nejlepššího odstupu signálu od šumu.

Literatura

- [1] KEZI SELVA VIJILA, C., P. KANAGASABAPATHY a S. JOHNSON. Adaptive Neuro Fuzzy Inference System for Extraction of fECG. In: 2005 Annual IEEE India Conference - Indicon [online]. IEEE, 2005, s. 224-227 [cit. 2017-05-21]. DOI: 10.1109/INDCON.2005.1590160. ISBN 0780395034.
- [2] PENHAKER, Marek a Martin AUGUSTYNEK. Zdravotnické elektrické přístroje 1. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2013, 411 s. ISBN 978-80-248-3107-7.
- [3] MARTINEK, Radek. Využití komplexních adaptivních metod zpracování signálů pro zpřesnění diagnostické kvality abdominálního fetálního elektrokardiogramu. 2014.
- [4] ASSALEH, Khaled. Extraction of Fetal Electrocardiogram Using Adaptive Neuro-Fuzzy Inference Systems. IEEE Transactions on Biomedical Engineering [online]. 2007, 54(1), 59-68 [cit. 2017-05-23]. DOI: 10.1109/TBME.2006.883728. ISSN 00189294.
- [5] RATHOD, s R a V R BANSOD. Separation of FECG from complex ECG in fetal monitoring. In: 2016 Online International Conference on Green Engineering and Technologies (IC-GET) [online]. IEEE, 2016, s. 1-5 [cit. 2017-05-23]. DOI: 10.1109/GET.2016.7916788. ISBN 978-1-5090-4556-3.
- [6] SARGOLZAEI, A.; FAEZ, K.; SARGOLZAEI, S. a new method for Foetal Electrocardiogram extraction using Adaptive Nero-Fuzzy Interference System trained with PSO algorithm. In: Electro/Information Technology (EIT), 2011 IEEE International Conference on. IEEE, 2011. p. 1-5.
- [7] TAKAGI, Tomohiro; SUGENO, Michio. Fuzzy identification of systems and its applications to modeling and control. IEEE transactions on systems, man, and cybernetics, 1985, 1: 116-132.
- [8] JANG, J.-SR. ANFIS: adaptive-network-based fuzzy inference system. IEEE transactions on systems, man, and cybernetics, 1993, 23.3: 665-685.
- [9] ZADEH, Lotfi A. Fuzzy sets. Information and control, 1965, 8.3: 338-353.
- [10] POKORNÝ, M., SROVNAL, V. Systémy s umělou inteligencí - Učební text a návody do cvičení. CZ.1.07/2.2.00/15.0113. VŠB - Technická univerzita Ostrava. Ostrava, 2012
- [11] MARTINEK, Radek, et al. Fetal ECG extraction based on adaptive neuro-fuzzy interference system. In: Communication Systems, Networks and Digital Signal Processing (CSNDSP), 2016 10th International Symposium on. IEEE, 2016. p. 1-6.

- [12] KSHIRSAGAR, P.; RATHOD, N. Artificial neural network. International Journal of Computer Applications, 2012.
- [13] HUDSON, D. L. a M. E. COHEN. Neural networks and artificial intelligence for biomedical engineering. New York: Institute of Electrical and Electronics Engineers, c2000. ISBN 0-7803-3404-3.
- [14] MARTINEK, Radek, Radana KAHANKOVA, Homer NAZERAN, et al. Non-Invasive Fetal Monitoring: a Maternal Surface ECG Electrode Placement-Based Novel Approach for Optimization of Adaptive Filter Control Parameters Using the LMS and RLS Algorithms. Sensors[online]. 2017, 17(6), 1154- [cit. 2017-12-27]. DOI: 10.3390/s17051154. ISSN 1424-8220.
- [15] REAZ, Mamun Bin Ibne; WEI, Lee Sze. Adaptive linear neural network filter for fetal ECG extraction. In: Intelligent Sensing and Information Processing, 2004. Proceedings of International Conference on. IEEE, 2004. p. 321-324.
- [16] PENHAKER, Marek. Lékařské diagnostické přístroje: učební texty. Ostrava: VŠB - Technická univerzita Ostrava, 2004. ISBN 80-248-0751-3.
- [17] JAMBUKIA, Shweta H., Vipul K. DABHI a Harshadkumar B. PRAJAPATI. Classification of ECG signals using machine learning techniques: a survey. In: 2015 International Conference on Advances in Computer Engineering and Applications [online]. IEEE, 2015, 2015, s. 714-721 [cit. 2018-02-04]. DOI: 10.1109/ICACEA.2015.7164783. ISBN 978-1-4673-6911-4.
- [18] VONDRÁK, Ivo. Umělá inteligence a neuronové sítě. Dot. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 1995. ISBN 80-7078-259-5.
- [19] HOPFIELD, John J. Neural networks and physical systems with emergent collective computational abilities. Proceedings of the national academy of sciences, 1982, 79.8: 2554-2558.
- [20] KAHÁNKOVÁ, Radana. Adaptivní metody extrakce abdominálního plodového elektrokardiogramu [online]. Ostrava, 2016 [cit. 2018-04-01]. Dostupné z: <http://hdl.handle.net/10084/115849>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.
- [21] MARTINEK, Radek, Michal KELNAR, Petr KOUDELKA, Jan VANUS, Petr BILIK, Petr JANKU, Homer NAZERAN a Jan ZIDEK. a novel LabVIEW-based multi-channel non-invasive abdominal maternal-fetal electrocardiogram signal generator. Physiological Measurement [online]. 2016, 37(2), 238-256 [cit. 2018-04-02]. DOI: 10.1088/0967-3334/37/2/238. ISSN 0967-3334. Dostupné z: <http://stacks.iop.org/0967-3334/37/i=2/a=238?key=crossref.b5fbdf21e3809d22c39c7c527446f4fb>

- [22] MARTINEZ, M., et al. Methods to evaluate the performance of fetal electrocardiogram extraction algorithms. In: *Computers in Cardiology 2001*. IEEE, 2001. p. 253-256.
- [23] JALALEDDINE, Sateh MS, et al. ECG data compression techniques-a unified approach. *IEEE transactions on Biomedical Engineering*, 1990, 37.4: 329-343.
- [24] ROONIZI, Ebadollah Kheirati; SASSI, Roberto. a signal decomposition model-based Bayesian framework for ECG components separation. *IEEE Transactions on Signal Processing*, 2016, 64.3: 665-674.
- [25] GOLBERGER, A., et al. PhysioBank, PhysioToolkit, and PhysioNet: Component of a New Research Resource for Complex Physiologic Signals. *Circulation*, 2000, 101.23: e215-e220.
- [26] VERDURMEN, Kim M. J., Carlijn LEMPERSZ, Rik VULLINGS, Christian SCHROER, Tammo DELHAAS, Judith O. E. H. VAN LAAR a S. Guid OEI. Normal ranges for fetal electrocardiogram values for the healthy fetus of 18–24 weeks of gestation: a prospective cohort study. *BMC Pregnancy and Childbirth* [online]. 2016, 16(1), - [cit. 2018-04-16]. DOI: 10.1186/s12884-016-1021-x. ISSN 1471-2393. Dostupné z: <http://bmcpregnancychildbirth.biomedcentral.com/articles/10.1186/s12884-016-1021-x>
- [27] CLIFFORD, Gari D, Ikaro SILVA, Joachim BEHAR a George B MOODY. Non-invasive fetal ECG analysis. *Physiological Measurement* [online]. 2014, 35(8), 1521-1536 [cit. 2018-04-16]. DOI: 10.1088/0967-3334/35/8/1521. ISSN 0967-3334. Dostupné z: <http://stacks.iop.org/0967-3334/35/i=8/a=1521?key=crossref.ed0b7cbee6665c91c9d2ce932d7091c1>
- [28] WU, Shuicai, et al. Research of fetal ECG extraction using wavelet analysis and adaptive filtering. *Computers in biology and medicine*, 2013, 43.10: 1622-1627.
- [29] CAMPS, G.; MARTINEZ, M.; SORIA, E. Fetal ECG extraction using an FIR neural network. In: *Computers in Cardiology 2001*. IEEE, 2001. p. 249-252.
- [30] REAZ, Mamun Bin Ibne; WEI, Lee Sze. Adaptive linear neural network filter for fetal ECG extraction. In: *Intelligent Sensing and Information Processing, 2004. Proceedings of International Conference on*. IEEE, 2004. p. 321-324.
- [31] KANJILAL, Partha Pratim; PALIT, Sarbani; SAHA, Goutam. Fetal ECG extraction from single-channel maternal ECG using singular value decomposition. *IEEE Transactions on Biomedical Engineering*, 1997, 44.1: 51-59.
- [32] DE LATHAUWER, Lieven; DE MOOR, Bart; VANDEWALLE, Joos. Fetal electrocardiogram extraction by blind source subspace separation. *IEEE transactions on biomedical engineering*, 2000, 47.5: 567-572.

- [33] MARTENS, Suzanna MM, et al. A robust fetal ECG detection method for abdominal recordings. *Physiological measurement*, 2007, 28.4: 373.

A Přílohy na CD/DVD

- Diplomová práce ve formátu PDF
- Softwarového rozhraní pro extrakci plodového EKG